Model prilagodljivog planiranja i praćenja proizvodnje

Gordić, Borislav

Doctoral thesis / Disertacija

2013

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Mechanical Engineering and Naval Architecture / Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:235:137187

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-25**

Repository / Repozitorij:

Repository of Faculty of Mechanical Engineering and Naval Architecture University of Zagreb

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

Sveučilište u Zagrebu

FAKULTET STROJARSTVA I BRODOGRADNJE

Borislav Gordić

MODEL PRILAGODLJIVOG PLANIRANJA I PRAĆENJA PROIZVODNJE

DOKTORSKI RAD

Zagreb, 2013

University of Zagreb

FACULTY OF MECHANICAL ENGINEERING
AND NAVAL ARCHITECTURE

Borislav Gordić

MODEL OF ADAPTABLE PRODUCTION PLANNING AND CONTROL

DOCTORAL THESIS

Zagreb, 2013

Sveučilište u Zagrebu

FAKULTET STROJARSTVA I BRODOGRADNJE

Borislav Gordić

MODEL PRILAGODLJIVOG PLANIRANJA I PRAĆENJA PROIZVODNJE

DOKTORSKI RAD

Mentor: Prof.dr.sc. Nedeljko Štefanić

Zagreb, 2013

University of Zagreb

FACULTY OF MECHANICAL ENGINEERING
AND NAVAL ARCHITECTURE

Borislav Gordić

MODEL OF ADAPTABLE PRODUCTION PLANNING AND CONTROL

DOCTORAL THESIS

Supervisor: Prof.dr.sc. Nedeljko Štefanić

Zagreb, 2013

PODACI ZA BIBLIOGRAFSKU KARTICU

UDK:	658.5.018.2
Ključne riječi:	plana pokusa, analiza varijance, model oponašanja, prilagodljivo planiranje i praćenje proizvodnje, diskretno korektivno dinamizirano optimiranje
Znanstveno područje:	tehničke znanosti
Znanstveno polje:	strojarstvo
Znanstvena grana:	proizvodno strojarstvo
Institucija gdje je rad izrađen:	Fakultet strojarstva i brodogradnje, Zagreb
Mentor:	Prof. dr. sc. Nedeljko Štefanić
Broj stranica:	XV; rad 186; prilozi 28
Broj slika:	34
Broj tablica:	27
Broj korištenih bibliografskih jedinica:	38
Datum obrane:	*12.07.2013.*
Povjerenstvo:	*Dr.sc. Predrag Ćosić, red. prof. – predsjednik* *Dr.sc. Nedeljko Štefanić, red. prof. - mentor* *Dr.sc. Andrej Polajnar, red. prof. Fakulteta za strojništvo, Maribor, R. Slovenija*
Institucija u kojoj je rad pohranjen:	Fakultet strojarstva i brodogradnje, Zagreb

ZAHVALA

Prije svega i prije svih, izuzetno sam zahvalan svojem mentoru, profesoru Nedeljku Štefaniću, na suradnji i vrlo korisnim savjetima, sugestijama i usmjeravanju u izradi doktorskog rada. Bio je pravi mentor - konstruktivan i otvoren, suradnički usmjeren i sa velikim ljudskim razumijevanjem, kako kod preuzimanja mentorstva tako i u razdoblju moje teške operacije i terapije.

Tijekom svojeg obrazovanja i rada od mnogih sam osoba imao prilike učiti i stjecati iskustva. No, moram reći da sam najviše naučio od pokojnog profesora Zvonka Fijana s kojim sam i najviše surađivao i koji me je usmjerio na otkrivanje novim spoznaja putem primjene raspoloživih znanja pa njemu pripada posebna zahvala.

Ovdje svakako moram spomenuti članove Povjerenstva za poslijediplomske studije, prof.dr. Predraga Ćosića te profesore Zavoda za industrijsko inženjerstvo i menadžment. Zahvalu svakako zaslužuje kolega Libor Burian kao i i mladi kolega Branimir Nadih za pomoć u izradi potrebnog softwarea za istraživanje i testiranja rezultata istraživanja.

Posebnu zahvalu dugujem rođakinji Miri Soro koja mi je dala poticaj da se nakon dužeg vremena prihvatim posla i izradim ovaj rad temeljem započetog istraživanja.

Svojim roditeljima neizmjerno sam zahvalan zbog ranog i stalnog upućivanja na stjecanje znanja i punu podršku koju sam od njih imao tijekom obrazovanja.

Članovima svoje najuže obitelji dugujem posebnu zahvalu zbog njihovog strpljenja i poticanja u radu, a posebnu u upućivanju za primjenu računala u izradi doktorskog rada.

Zagreb, lipanj 2013.

Borislav Gordić

U spomen na djeda Marka Gordića i ujaka Ivicu Ferenčevića.

SADRŽAJ

Predgovor VI

Sažetak VII

Summary VIII

Popis slika IX

Popis tablica XI

Popis oznaka XIII

Popis kratica XVI

1. UVOD U ISTRAŽIVANJE 1
   1.1. Općenito o istraživanju 1
   1.2. Izbor i obrazloženje teme za istraživanje 2
2. PREGLED DOSADAŠNJIH ISTRAŽIVANJA 10
   2.1. Istraživanje znanstvene literature 10
   2.2. Istraživanje znanstvenih članaka 15
   2.3. Sintetski pregled znanstvenih istraživanja 22
   2.4. Ocjena planiranja i praćenja u praksi 26
   2.5. Ciljevi, hipoteza i očekivani doprinos istraživanja 29
3. POSTAVLJANJE ZADATKA ZA ISTRAŽIVANJE 32
   3.1. Opis problema za istraživanje 32
   3.2. Kriteriji i mjerila 37
      3.2.1. Kriterij U_1 – osjetljivost planiranja i praćenja 39
      3.2.2. Kriterij U_2 – zadovoljenost rokova 41
      3.2.3. Kriterij U_3 – efikasnost upravljanja zalihama 43
      3.2.4. Sintetski kriterij U – uspješnost planiranja i praćenja 44
   3.3. Model prilagodljivog planiranja i praćenja 46
4. ISTRAŽIVANJE NA PRIMJERU 60
   4.1. Stanje u proizvodnji 61
   4.2. Stanje u plasmanu proizvoda 64
   4.3. Stanje u nabavi repromaterija 66
   4.4. Stanje u operativnom planiranju i praćenju proizvodnje 67

4.5. Ocjena postojećeg stanja 73
4.6. Utvrđivanje utjecajnih faktora 75
4.7. Utjecajni faktori za istraživanje na modelu 79
5. ISTRAŽIVANJE NA MODELU 85
5.1. Primjena modela za istraživanje 85
5.2. Dobiveni rezultati pokusa 90
5.3. Analiza varijance za kriterij U1 93
5.4. Analiza varijance za kriterij U2 96
5.5. Analiza varijance za kriterij U3 98
5.6. Analiza varijance za sintetski kriterij U 101
5.7. Dodatna analiza varijance 107
5.8. Zaključna analiza rezultata 110
6. MODELIRANJE I OPTIMIZACIJA PLANIRANJA I PRAĆENJA 113
6.1. Poopćenje rezultata istraživanja na primjeru 113
6.2. Ocjena kliznog planiranja i praćenja 122
6.3. Regresijska analiza rezultata pokusa 126
6.4. Modeliranje prilagodljivog planiranja i praćenja 129
6.5. Optimizacija prilagodljivog planiranja i praćenja 140
7. ZAVRŠNO RAZMATRANJE ISTRAŽIVANJA 152
7.1. Dokaz hipoteze 152
7.2. Ispitivanje modela korektivnog optimiranja 156
7.3. Postupak određivanja planiranja i praćenja 169
7.4. Zaključak o istraživanju 175
8. LITERATURA 184
9. PRILOG P1
9.1. Ulazni podaci za istraživanje na praktičnom primjeru P1
9.2. Program i rezultati ispitivanja modela korektivnog optimiranja P12
ŽIVOTOPIS
BIOGRAPHY

PREDGOVOR

Na proizvodne procese danas sve više utječe individualizacija potreba i česte, značajne promjene u okruženju. To nužno uvjetuje potrebu korekcija i usklađivanja planova proizvodnje, uz primjenu metoda i tehnika optimizacije, u funkciji kontinuiranog prilagođavanja poduzeće potrebama okoline i svojem stanju. Korištenjem postupka oponašanja na modelu i faktorskog plana pokusa s analizom varijance, može se utvrditi djelovanje utjecajnih faktora i procesa planiranja i praćenja na uspješnost poslovnog sustava, uz korištenje kriterija i mjerila za ocjenjivanje uspješnosti planiranja i praćenja.

Brojna istraživanja u zadnjih 10 godina pokazuju da se sve više nameće potreba prilagođavanja metoda optimizacije specifičnim zahtjevima pojedinih tipova proizvodnje uz sve veću primjenu metoda oponašanja u svrhu korekcija planova i prilagodljivosti proizvodnje promjenama. Zato se važnim smatra postupak modeliranja i optimizacije procesa planiranja i praćenja putem utvrđivanja utjecajnih faktora na uspješnost planiranja i praćenja u uvjetima promjena, temeljem čega se može konkretizirati model i optimizirati proces planiranja i praćenja za proizvodni sustav. Uz to je potrebno odabrati odgovarajući model dinamiziranog programiranja kao polazne metode optimizacije, a oponašanje kao dodatnu tehniku za optimizaciju korekcija plana proizvodnje prema predloženim kriterijima i mjerilima.

Postavljena hipoteza istraživanja da izbor modela i optimizacija procesa planiranja i praćenja proizvodnje značajno utječe na uspješnost i prilagodljivost proizvodnog sustava i poslovanja u uvjetima dinamičnih promjena u okruženju i samom proizvodnom sustavu ovdje je i dokazana. Ujedno je potvrđeno da će kod primjene diskretnog korektivnog dinamiziranog optimiranja planovi svih nivoa biti objektivniji i bliži realnosti nego kod bilo kojeg drugog modela optimiranja u procesu planiranja i praćenja proizvodnje.

Navedeni matematički dokaz hipoteze ovog istraživanja pokazuje kako je tek sa korektivnim optimiranjem putem oponašanja moguće ostvariti prilagodbu stvarnim uvjetima u okruženju i samom sustavu. Modeli diskretnog korektivnog dinamiziranog optimiranja ne prilagođavaju stvarnost matematičkoj metodi već se matematičke metode prilagođavaju postizanju veće realnosti rješenja planova proizvodnje. Pri tome se, u traženju najpovoljnijeg riješenja od mogućih, dobivaju realnija rješenja uz manja odstupanja od stvarnih uvjeta optimiranja planova proizvodnje.

SAŽETAK

Planiranje i praćenje proizvodnje tretirano je kao proces s utjecajem na upravljanje te prilagodljivost i fleksibilnost poslovnog sustava u uvjetima većih i intenzivnih promjena. To nužno uvjetuje potrebu korekcija i usklađivanja planova proizvodnje uz primjenu metoda i tehnika optimizacije, a u funkciji kontinuiranog prilagođavanja poduzeće potrebama okoline i svojem stanju. Izvršeno je probno istraživanje na konkretnom primjeru temeljem kojeg je putem oponašanja na modelu i faktorskog plana pokusa analizom varijance utvrđeno djelovanje utjecajnih faktora i procesa planiranja i praćenja na uspješnost poslovnog sustava. U tu svrhu odabrani su novi, sintetizirani kriteriji i mjerila za ocjenjivanje uspješnosti procesa planiranja i praćenja, koji predstavljaju odgovarajući znanstveni doprinos.

Predložen je postupak modeliranja i optimizacije procesa planiranja i praćenja putem utvrđivanja utjecajnih faktora na uspješnost planiranja i praćenja u uvjetima promjena, temeljem čega se može konkretizirati model i optimizirati planiranje i praćenje za proizvodni sustav. Kod predloženog modela diskretnog korektivnog dinamiziranog optimiranja korišteno je dinamizirano programiranje kao polazna metoda optimizacije a oponašanje kao dodatna tehnika za optimizaciju korekcije osnovnog operativnog plana proizvodnje prema predloženim kriterijima i mjerilima. Navedeni postupci i model optimizacije predstavljaju konkretan znanstveni doprinos i dokaz postavljene hipoteze istraživanja.

Ključne riječi: plana pokusa, analiza varijance, model oponašanja, prilagodljivo planiranje i praćenje proizvodnje, diskretno korektivno dinamizirano optimiranje

SUMMARY

Production planning and control has been treated as a process influencing the management as well as adaptibility and flexibility of a business system in the conditions of major and intensive changes. This necessarily asks for the need of correction and adjustment of production plans and application of optimization methods and techniques, in order to provide a continuous adjustment of an enterprise to the needs of the environment and its own state. A trial research was performed on a particular case, and on the basis of it, using a simulation model and adequate design of experiments, the influence factors have been defined, and by applying the analysis of variance the effect of influence factors and production planning and control on the successfulness of the business system have been determined. For this purpose, new synthesized criteria and measures have been selected for the evaluation of successfulness of production planning and control, what is representing corresponding scientific contribution.

A procedure for modelling and optimization of production planning and control is proposed by determination of the factors influencing the successfulness of production planning and control in the conditions of changes, on the basis of which it is possible to realize the model and optimize planning and control of a production system. In doing so, dynamised programming is used as the starting optimization method, while the simulation is applied as an additional technique for the optimization of the basic operational production plan correction in accordance with the proposed criteria and measures. These procedures and the model of optimization present the exact scientific contribution and the proof of appointed hypothesis of research.

Key words: design of experiments, analysis of variance, simulation model, adaptive production planning and control, discrete corrective dynamised optimization

POPIS SLIKA

Slika 1. Shematski prikaz sustava s organizacijskim procesom 3

Slika 2. Opći blok-dijagram organizacijskog procesa poduzeća 5

Slika 3. Struktura poduzeća i veza procesa 7

Slika 4. Opći model proizvodnog sustava 8

Slika 5. Shematski prikaz prostornih granica u istraživanju 32

Slika 6. Shematski prikaz principa kliznog planiranja i praćenja 48

Slika 7. Tablica faktorskog plana pokusa 2^5 za istraživanje 51

Slika 8. Skraćeni blok-dijagram programa za oponašanje procesa 53

Slika 9. Shematski prikaz toka proizvodnje proizvoda u proizvodnji posuđa 62

Slika 10. Zakon distribucije izostanaka izvršioca u prodaji i otpremi 70

Slika 11. Zakon distribucije vremena trajanja zastoja opreme u proizvodnji dijelova 72

Slika 12. Zakon distribucije vremena trajanja zastoja opreme u proizvodnji poluproizvoda 72

Slika 13. Zakon distribucije vremena trajanja zastoja opreme u proizvodnji proizvoda 72

Slika 14. Zakon distribucije vremena trajanja izostanaka izvršioca u proizvodnji 73

Slika 15. Prosječna odstupanja rezultata modela optimizacije od realizacije 124

Slika 16. Shema odvijanja procesa planiranja i praćenja 130

Slika 17. Opći shematski prikaz kliznog planiranja i praćenja 134

Slika 18. Klizno planiranje i praćenja za duže osnovno plansko razdoblje 137

Slika 19. Klizno planiranje i praćenja za srednje osnovno plansko razdoblje 137

Slika 20. Klizno planiranje i praćenja za kraće osnovno plansko razdoblje 138

Slika 21. Shematski prikaz opće postavke dinamičkog programiranja 142

Slika 22. Shematski prikaz modela dinamiziranog programiranja 143

Slika 23. Određivanje optimalne varijante korekcije osnovnog plana 146

Slika 24. Shematski prikaz diskretnog korektivnog dinamiziranog optimiranja 148

Slika 25. Skraćeni blok-dijagram diskretnog korektivnog dinamiziranog optimiranja 151

Slika 26. Prikaz matematičke optimizacije pomoću skupova 152

Slika 27. Prikaz tijeka diskretnog korektivnog dinamiziranog optimiranja 153
Slika 28. Prikaz dokaza hipoteze pomoću skupova 154
Slika 29. Blok-dijagram ispitivanja različitih modela optimizacije 162
Slika 30. Shematski prikaz podloga i postupka za modele optimizacije za ispitivanje 164
Slika 31. Prikaz odstupanja količina po varijantama ispitivanja za model **A** 168
Slika 32. Prikaz odstupanja količina po varijantama ispitivanja za model **B** 168
Slika 33. Prikaz odstupanja količina po varijantama ispitivanja za model **C** 168
Slika 34. Prikaz odstupanja količina po varijantama ispitivanja za model **D** 169

POPIS TABLICA

Tablica 1. Realizacija prodaje i proizvodnje po grupama proizvoda 61

Tablica 2. Pregled vrijednosti obilježja i ocjena za operativno planiranje i praćenje u objektu istraživanja 74

Tablica 3. Prva transformacija podataka tržišta prodaje 87

Tablica 4. Druga transformacija podataka tržišta prodaje 88

Tablica 5. Matrica nabave sirovina i dijelova 89

Tablica 6. Usporedba i testiranje pokazatelja uspješnosti planiranja u stvarnosti i na modelu 90

Tablica 7. Dobiveni rezultati pokusa po svim kriterijima i izvršenim ponavljanjima 91

Tablica 8. Analiza varijance za kriterij $\mathbf{U_1}$ u pokusima $\mathbf{2^5}$ x 6 94

Tablica 9. Analiza varijance za kriterij $\mathbf{U_2}$ u pokusima $\mathbf{2^5}$ x 6 97

Tablica 10. Analiza varijance za kriterij $\mathbf{U_3}$ u pokusima $\mathbf{2^5}$ x 6 100

Tablica 11. Analiza varijance za kriterij **U** u pokusima $\mathbf{2^5}$ x 6 102

Tablica 12. Analiza varijance za kriterij **U** u pokusima $\mathbf{2^4}$ x 6, bez faktora **B** 105

Tablica 13. Analiza varijance za kriterij **U** u pokusima $\mathbf{2^4}$ x 6, bez faktora **C** 106

Tablica 14. Analiza varijance za kriterij **U** u pokusima $\mathbf{2^5}$ x 6 sa smanjenom razlikom nivoa faktora 108

Tablica 15. Analiza varijance za kriterij **U** u pokusima $\mathbf{2^5}$ x 6 s većom proizvodnjom po narudžbi 109

Tablica 16. Analiza varijance za kriterij $\mathbf{U_1}$ u pokusima $\mathbf{2^4}$ x 6 sa kondenziranim faktorima **A** i **C** 117

Tablica 17. Analiza varijance za kriterij $\mathbf{U_2}$ u pokusima $\mathbf{2^4}$ x 6 sa kondenziranim faktorima **A** i **C** 118

Tablica 18. Analiza varijance za kriterij $\mathbf{U_3}$ u pokusima $\mathbf{2^4}$ x 6 sa kondenziranim faktorima **A** i **C** 119

Tablica 19. Analiza varijance za kriterij **U** u pokusima $\mathbf{2^4}$ x 6 sa kondenziranim faktorima **A** i **C** 120

Tablica 20. Usporedba i testiranje pokazatelja uspješnosti i prilagodljivosti primjenom kliznog planiranja i praćenja u modelu za proizvodnju većinom za zalihe 123

Tablica 21. Usporedba i testiranje pokazatelja uspješnosti i prilagodljivosti primjenom kliznog planiranja i praćenja u modelu za proizvodnju većinom po narudžbi 124

Tablica 22. Regresijska analiza rezultata pokusa $\mathbf{2^4}$ x 6 sa kondenziranim faktorima **A** i **C** 127

Tablica 23. Obilježja proizvodnje iz korištenih praktičnih primjera 163

Tablica 24. Ograničenje kapaciteta proizvodnje po mjesecima 163

Tablica 25. Rezultati ispitivanja modela optimizacije na primjeru proizvodnje posuđa 166

Tablica 26. Rezultati ispitivanja modela optimizacije na primjeru proizvodnje autostakla 166

Tablica 27. Odstupanja količina i profitne stope po ispitivanim modelima i proizvodnjama 169

POPIS OZNAKA

Oznaka	Značenje oznake
U_1	osjetljivost planiranja i praćenja
U_2	zadovoljenost rokova
U_3	efikasnost upravljanja zalihama
U	uspješnost planiranja
x_{1ij}	omjer 1/12 godišnjeg plana GP i mjesečne prodaje grupe proizvoda
x_{2ij}	omjer mjesečnog plan MP i mjesečne prodaje grupe proizvoda
x_{3ij}	omjer mjesečne proizvodnje PR i mjesečne prodaje grupe proizvoda
x_{4ij}	omjer plana i proizvodnje s mjesečnom prodajom grupe proizvoda
$\bar{x}$	srednja vrijednost omjera godišnjih i mjesečnih planova te realizacije proizvodnje u odnosu na izvršeni plasman
$\sigma_{\bar{x}}$	standardna devijacija aritmetičke sredine omjera planova i realizacije proizvodnje u odnosu na izvršeni plasman
R	ukupni godišnji broj postavljenih rokova (dana za isporuke)
R_z	godišnji broj nepoštivanih rokova isporuke (s kašnjenjem)
$\bar{x}_z$	prosječni broj dana kašnjenja u isporukama
$\bar{x}_{DI}$	prosječan broj dana postavljen kao rok isporuke
$\bar{z}_{p_{ij}}$	prosječno dnevno stanje zaliha grupe proizvoda u svakom mjesecu
$\bar{x}_{p_{ij}}$	količina isporučene grupe proizvoda u svakom mjesecu
$\bar{z}_{s_{ij}}$	prosječno dnevno stanje zaliha svake sirovine u svakom mjesecu
$\bar{x}_{us_{ij}}$	količina utrošene svake sirovine u svakom mjesecu
K_{U_1}	koeficijent osjetljivosti planiranja i praćenja
K_{U_2}	koeficijent zadovoljenosti rokova
K_{U_3}	koeficijent efikasnosti upravljanja zalihama
K_{U_2}	koeficijent uspješnosti planiranja
O_p	prosječan odnos stanja mjesečnih zaliha i mjesečno isporučenih količina proizvoda
O_s	prosječan odnos stanja mjesečnih zaliha i mjesečno utrošenih količina repromaterijala
$\bar{x}_{rp}$	prosječna realizacija proizvodnje u odnosu na planove

S_T	stupanj točnosti planova
S_V	stupanj varijacije planova
U_{zr}	učešće zadovoljenih rokova
N_k	nivo kašnjenja isporuka
y_{ijklm}	vrijednosti u faktorskom planu pokusa 2^5
E	efekti djelovanja svakog utjecajnog faktora i njihovih interakcija
$(\sigma_E)^2$	varijanca efekata u analizi varijance
$(\sigma_o)^2$	varijanca ostatka u analizi varijance
$F_{rač.}$	značajnost utjecajnih faktora i interakcija
$F_{tab.}$	kritična tabelarna vrijednost značajnosti utjecajnih faktora
G_{max}	Kohrenov kriterij u regresijskoj analizi
b_i	koeficijent regresije
K_i	intenzitet kliznog planiranja i praćenja
NP_i	nivo, razdoblje tretiranog plana
P_{pr}	pouzdanost proizvodnje
P_p	pouzdanost prodaje
P_n	pouzdanost nabave
P_{pp}	pouzdanost planiranja i praćenja
Q_{ij}^g	gornja granica potražnje proizvoda
Q_{ij}^d	donja granica potražnje proizvoda
Qd_{ij}	očekivane dodatne narudžbe proizvoda u nekom razdoblju
Qv_{ij}	neočekivane dodatne narudžbe proizvoda u nekom razdoblju
S_{i+j}	skup mogućnosti rješenja optimizacije u razdoblju korekcije
S_r	skup realne mogućnosti rješenja
S_d	skup odstupanja (greška)
$S_{p_{i+j}}$	skup promjena za razdoblje korekcije
S_o	skup optimalne mogućnosti rješenja
$S_{o_{i+j}}$	dio optimalne mogućnosti rješenja u razdoblju korekcije
$S_{o_{i+j}}^j$	korigirani dio optimalnog plana nakon razdoblja korekcije
$S_{k_{i+j}}$	skup korekcija plana nakon razdoblja korekcije
PG	stupanj prilagodljivosti modela optimiranja proizvodnje

GP	gubitak profitne stope kod korekcije planova proizvodnje
ΔQi	razlika planiranih i realiziranih količina proizvoda
$\boldsymbol{KS_i}$	pokazatelj isplativosti proizvoda
$\boldsymbol{Kp_{ij}}$	pokazatelj korekcije proizvoda
$\boldsymbol{ZK_i}$	učešće proizvoda u zauzimanju kapaciteta
$\boldsymbol{PS_i}$	profitna stopa proizvoda

POPIS KRATICA

Kratica	Objašnjenje
PP	planiranje i praćenje, općenito
PPP	planiranje i praćenje proizvodnje po svim nivoima
OPPP	operativno planiranje i praćenje proizvodnje unutar godine
MRP	material requirements planning (planiranje materijalnih zahtjeva)
ERP	enterprise resource planning (planiranje resursa poduzeća)
MPC	manufacturing planning and control (planiranje i praćenje izrade)
SCM	supply chain management (upravljanja nabavnim lancem)
JIT	just-in-time (proizvodnja na vrijeme)
MTO	make-to-order (proizvodnja po narudžbi)
MTS	proizvodnja za zalihe
S&OP	sales and operations planning (planiranje prodaje i djelovanja)
TP	terminski plan
OP	osnovni operativni plan
VP	viši operativni plan
SVP	najviši operativni plan (godišnji)
T_k	razdoblje korekcije plana
IPP	intenzitet kliznog planiranja i praćenja
UP	uspješnost proizvodnje-poslovanja
IK	iskoristivost kapaciteta
PF	profitna stopa
EK	efikasnost korekcije plana
PT	promjena troškova
IPP	indeks promjene prihoda i profita

1. UVOD U ISTRAŽIVANJE

1.1. Općenito o istraživanju

Istraživanje kao osnovni pokretač napretka i razvoja ljudskog društva poznati je proces koliko i povijest čovječanstva. Njegov značaj i uloga postaju s vremenom sve važniji pa danas dolazimo do konstatacije da istraživanja postaju nužnost ne samo za napredak ljudskog društva već prvenstveno za njegov opstanak. Na kraju i taj paradoks postaje predmet sve većeg i intenzivnijeg istraživanja nastojeći pri tome da sam čovjek bude i stvaralac i korisnik i regulator svih dobrobiti napretka.

Eksplozija znanosti, u pravom smislu te riječi, traži danas ne samo određene rezultate kao posljedicu istraživanja već i novi kvalitet samog procesa istraživanja. Glavni činilac tog procesa postaje znanost kao skup sistematiziranih i argumentiranih znanja o objektivnoj stvarnosti do koje se došlo svjesnom primjenom objektivnih metoda u istraživanju.

Danas, kada se sve intenzivnije i obimnije istražuju sve složeniji sustavi i procesi na sveobuhvatan način, ona postaje sve manje slobodna i nezavisna a sve više usmjerena i organizirana da proširuje saznanja i ostvaruje rezultate u jednom ili više područja znanosti. Pri tome se kao preduvjet dobrog istraživanja sve više koriste moderna pomagala, od računala pa nadalje, te organizirani timski rad, a sve se manje utjecaja oko toga prepušta slučaju.

Motiv nije samo zadovoljenje čovjekove znatiželje, već potreba da se uspješno riješe prisutni problemi s ciljem povećanja standarda čovjeka i društva u cjelini, a uz to je prisutna sve veća svijet i briga o zaštiti okoline i opstanku čovječanstva.

Razvijena društva su shvatila zakonitost da je potreba za istraživanjima to veća što je stupanj njihovog razvoja viši i zato oni danas izdvajaju sve veća sredstva za potrebe istraživanja. Naravno da i tu postoje određena ograničenja i prepreke, a one su to veće što je niži stupanj razvoja nekog društva. No, znajući da se jedino temeljitim i sveobuhvatnim istraživanjima mogu premostiti prepreke i riješiti problemi na putu k višem standardu i većoj kvaliteti života, a uz brigu o okolišu i opstanku, svjesno se izdvajaju sve veća sredstva za potrebe znanosti, pa čak i na uštrb izdvajanja za ostale potrebe društva.

U još specifičnijem položaju se nalaze tranzicijska društva, no na žalost niska je svijest o tome da manja društva mogu lakše prebroditi objektivne probleme tranzicije i razvoja većim obrazovanjem ljudi i intenziviranjem vlastitih istraživanja uz veću ulogu znanosti.

To ne znači da ne treba koristiti tuđa znanja i iskustva, već naprotiv, treba ih primjenjivati na način da se ista prilagode našim problemima i potrebama. Pri tome moramo biti ne samo korisnici određenih znanstvenih dostignuća, nego i ravnopravno sudjelovati u zajedničkim istraživanjima i svjetskoj razmjeni saznanja nudeći svoje spoznaje i iskustva u zamjenu za tuđa. Na taj se način neće povećavati razlike između razvijenih i nerazvijenih sredina već će se taj jaz sve više smanjivati, a što bi trebao biti zajednički interes čovječanstva na putu opstanka, razvoja i mira.

Obzirom da je istraživanje složen proces, ne samo iz razloga potrebe da riješi određene probleme i utvrdi zakonitosti te donese korisne, primjenjive rezultate, nego i zbog složenosti društvenih uvjeta u kojima se istraživanja odvijaju, značajan problem istraživanja predstavlja pristup, način i ciljevi realizacije nekog istraživanja. To znači da nije dovoljno samo raditi na ostvarenju određenih rezultata kroz proces istraživanja već pri tome moraju tražiti i razvijati novi pravci, načini i metode rada.

1.2. Izbor i obrazloženje teme istraživanja

Danas su većem dijelu svijeta mnogobrojne znanstvene spoznaje poznate i lakše dostupne, a sve veći dio ih je i praktično primijenjen te one predstavljaju značajan resurs čovječanstva, zajedno s mnogim prirodnim i društvenim resursima. Istovremeno je i poznata činjenica kako je glavni uzrok razlika u stupnju razvijenosti pojedinih društava prvenstveno u stupnju iskorištenosti i organiziranosti te upravljanju u korištenju tih potencijala.

Također je činjenica da su za organiziranje i pokretanje korištenja tih resursa potrebna ogromna ulaganja, a posebno financijska. No, efekti će biti veći, a potrebna ulaganja manja, ako je nivo organiziranosti veći a time i kvalitetnije planiranje i praćenje kao njen dio.

Isto tako smo svjedoci sve veće potrebe prisutnosti organizacije s planiranjem i praćenjem u našim pojedinačnim a životnim i svakodnevnim aktivnostima, pa možemo reći da nema niti jednog područja života i rada gdje oni nisu prisutni. Pri tome pod organizacijom podrazumjevamo prvenstveno skup procesa kao načina rada i odnosa s odgovarajućim algoritmima, međusobno povezanih i usklađenih, a s ciljem da se povremeno ili kontinuirano izvrši realizacija postavljenih ciljeva-potreba te ostvare planirani rezultati.

Na slici 1. shematski je prikazan takav jedan sustav s organizacijskim procesom.

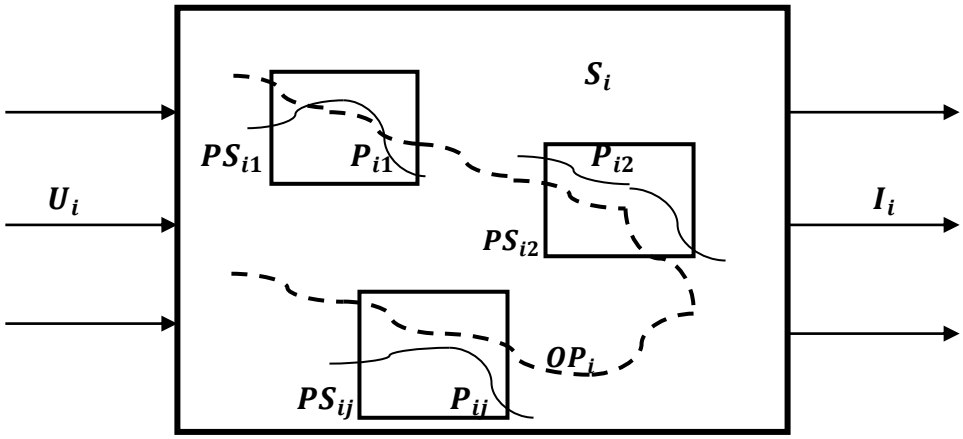

U_i – ulazne informacije PS_{ij} – podsustavi sustava S_i P_{ij} – procesi sustava S_i
I_i – izlazne informacije OP_i – organizacijski proces sustava S_i

Slika 1. *Shematski prikaz sistema s organizacijskim procesom*

Proces planiranja i praćenja je dio organizacijskog procesa u kojem se obavlja povezivanje i usklađivanje pojedinačnih organizacijskih procesa u realizaciji postavljenih ciljeva cjeline. U ovom se istraživanju obrađuju prvenstveno procesi, a struktura sustava odabranog kao mjesto-područje istraživanja obrađuje se u onoj mjeri u kojoj je ona značajna i utjecajna na procese. Pri tome se proces tretira kao skup logički povezanih i usklađenih aktivnosti s pripadajućim alogoritmima, ulaznim i izlaznim informacijama.

Zbog navedenog pristupa u radu nadalje će se koristiti pojmovi i skraćenice vezane za proces planiranja i praćenja kako slijedi:

1. **Planiranje i praćenje (PP)** – podrazumijeva planiranje i praćenje u bilo kojem organizacijskom procesu i svim sadržajima u njemu
2. **Planiranje i praćenje proizvodnje** (PPP) – obuhvaća se planiranje i praćenje svih sadržaja proizvodnje za sva razdoblja planiranja
3. **Operativno planiranje i praćenje proizvodnje (OPPP**) – odnosi se na planiranje i praćenje proizvodnje za razdoblja unutar jedne godine

Proces planiranja i praćenja čini najveći dio organizacijskog procesa obzirom na značaj, intenzitet izvođenja i prisutnost te ulazno i izlazno povezivanje sustava s okruženjem. U okviru procesa planiranja i praćenja podrazumijevamo i pripadajući informatički podsustav kao dio njegove strukture i sastavni dio samog procesa planiranja i praćenja.

Proces planiranja nije izvediv bez praćenja pa stoga oni čine jedinstveni proces. Nakon planiranja, u fazi realizacije obavlja se praćenje ne samo zbog utvrđivanja da li se planiranje izvodi kako je definirano i kakvi su rezultati, već i zbog toga da se na vrijeme utvrde eventualno nastali poremećaji koji se u nastavku planiranja usklađuju sa postojećim stanjem i ciljevima, i obrnuto. To znači da se i planiranje i praćenje izvode povezano i kontinuirano pa se taj proces može zvati upravljanje organizacijskim procesom određenog sustava, kako se najčešće i naziva u znanosti i praksi.

Da bi proces planiranja i praćenja proizvodnje, kao osnovno područje istraživanja, bio cjelovito i svestrano obrađen, potrebno je kao područje istraživanja obuhvatiti i dijelove drugih procesa u kojima se isti realizira te veze s okruženjem, a što je važno zbog povratnih sprega.

Opći blok-dijagram organizacijskog procesa nekog proizvodnog poduzeća prikazan je na slici 2. gdje je svaki blok aktivnosti u prikazu zapravo jedan proces a ovim prilogom se želi na pojednostavljeni način prikazati organizacijski proces proizvodnog poduzeća te mjesto i uloga planiranja i praćenja. Sve veze između pojedinih procesa ostvaruju se na nivou odgovarajućih aktivnosti a one bi na slici bile vidljive u punoj mjeri kada bi se procesi razradili do nivoa pojedinačnih aktivnosti.

Može se reći da će područje ovog istraživanja biti proces planiranja i praćenja proizvodnje s onim dijelovima drugih organizacijskih procesa i proizvodnjom koji su na njega neposredno i operativno vezani te predstavljaju konkretnu realizaciju planiranja i praćenja proizvodnje i daju povratne informacije za praćenje. Zato će se u daljnjem tekstu proces planiranja i praćenja proizvodnje kao područje istraživanja tretirati u širem smislu, zajedno s procesima neposredne realizacije tj. proizvodnje.

Razlozi za izbor ovog područja za istraživanje proizlaze iz višegodišnjeg neposrednog sudjelovanja autora u izvođenju i razvoju organizacijskog procesa u više područja ljudske djelatnosti, prvenstveno proizvodnje, a ogledaju se u sljedećem:

1. Planiranje i praćenje proizvodnje je dio procesa upravljanja i objedinjuje većinu procesa nekog organizacijskog sustava pa tako povezuje proizvodnju i ostale procese sustava sa okolinom u funkciji realizacije potreba okoline i samog sustava.

2. Kvalitet planiranja i praćenja proizvodnje posredno i neposredno utječe na rezultate dijelova nekog organizacijskog sustava, a time značajno utječe na njegovu prilagodbu promjenama u okruženju i sustavu te njegov ukupan rezultat.

3. Potreba definiranja procesa planiranja i praćenja proizvodnje u okviru ukupne organizacije proizvodnog sustava, a posebno u realizaciji u uvjetima promjena i poteškoća u sustavu, te utvrđivanje njegovog utjecaja u upravljanju proizvodnjom.
4. Nedostatak jedinstvenih kriterija i mjerila za određivanje optimalnih modela-rješenja procesa planiranja i praćenja proizvodnje te utvrđivanje njegove efikasnosti i uspješnosti, pogotovo u uvjetima promjena i nestabilnosti.

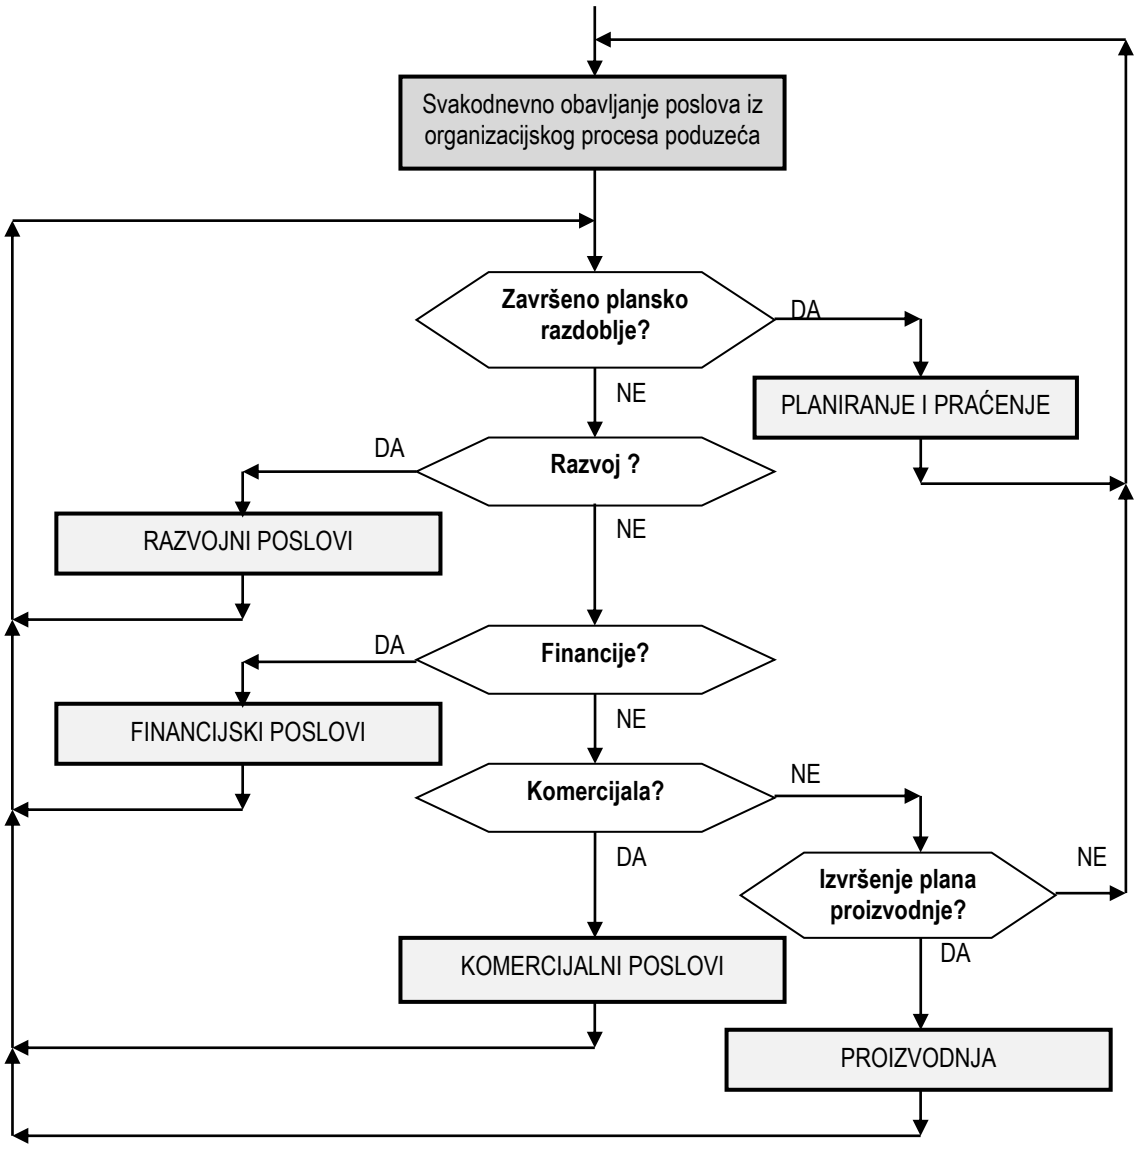

Slika 2. *Opći blok-dijagram organizacijskog procesa poduzeća*

Ciljno usmjeren, dinamičan i organiziran proces planiranja i praćenja proizvodnje polazi od činjenice da danas u okruženju punom naglih, velikih i brojnih neočekivanih promjena nije cilj samo optimizirati stanje poduzeća-sustava u smislu dobiti ili profita. Posebno važan cilj je optimizirati prilagodljivost i fleksibilnost kao pokazatelje njegove dinamičke optimizacije rada i poslovanja, pri čemu se kao kriteriji uzimaju minimalni troškovi ili vremena realizacije poslova u proizvodnji.

Može se reći da je cilj planiranja i praćenja proizvodnje pronalaženje rješenja za maksimalno zadovoljavanje potreba tržišta kroz realizaciju u proizvodnji uz maksimalno mogući poslovni uspjeh poduzeća, putem odgovarajućih aktivnosti, metoda i tehnika rada. Uz to je bitno stalno povezivanje sadržaja iz okoline-tržišta, proizvodnje i logističkih-pratećih sadržaja i parametara kao usklađene cjeline s optimalnim rezultatima.

Samo stalna veza sa sustavima i procesima u okolini, kontinuirano dinamičko prilagođavanje potrebama okoline-tržišta i stalna, intenzivna suradnja između svih dijelova promatranog sustava-poduzeća omogućava njegov opstanak i razvoj pri čemu se najveći dio tih aktivnosti odvija u procesu planiranja i praćenja proizvodnje. To potvrđuje potrebu povezivanja stvarnih uvjeta u proizvodnom sustavu i njegovom okruženju putem procesa planiranja i praćenja proizvodnje uz primjenu metoda i tehnika optimizacije po odabranim kriterijima.

Na slici 3. prikazana je pojednostavljena shematska struktura poduzeća i veza procesa gdje je vidljiv položaj i uloga procesa planiranja i praćenja proizvodnje koji se u ovom radu istražuje.

Intenzivne veze između procesa podrazumijevaju višekratno dnevno komuniciranje i povezivanje putem odgovarajućih zajedničkih aktivnosti. Stalne veze podrazumijevaju redovito komuniciranje i povezivanje procesa kontinuirano, jednom dnevno ili nekoliko puta tjedno. Povremene veze znače komuniciranje i povezivanje procesa po potrebi i kod izrade ili usklađivanja operativnih planova.

Može se reći da je planiranje i praćenje općenito, a isto tako i za proizvodnju, produžena ili pridružena ruka sustava i procesa upravljanja poslovanjem proizvodnog poduzeća i u stvari čini dio ukupnog procesa upravljanja.

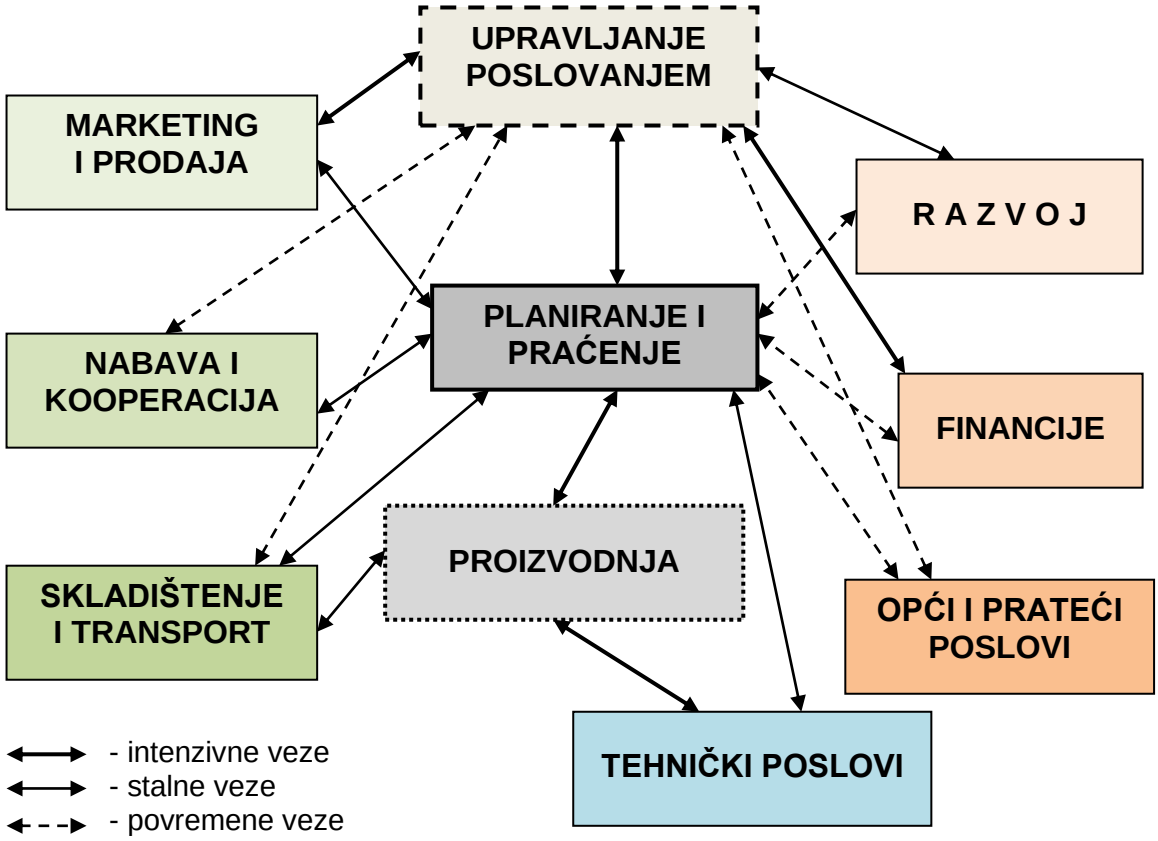

Slika 3. *Struktura poduzeća i veza procesa*

Ulazeći u detalje obrazloženja izbora područja istraživanja može se konstatirati da je svaka odluka prvenstveno reakcija na neku situaciju i da su one usko povezane. Radi se o tome da je najveći dio postojećih saznanja, pristup i metode rada u planiranju i praćenju istraživan i razvijan za uglavnom stabilnije situacije za rad ili neke specifične okolnosti i uvjete pa su tome i primjereni, posebno kroz niz razvijenih metoda i tehnika rada.

Danas se sve više postavljaju zahtjevi za planiranjem i praćenjem koji će moći odgovoriti većem broju pojedinačnih zahtjeva postavljenih pred neki organizacijski proces te velikoj brzini i broju promjena koje treba slijediti uz odgovarajuću tehnologiju i njen razvoj.

Od posebnog bi interesa bilo istraživanje sustava i procesa za donošenje odluka i to ne samo u smislu predviđanja i na bazi procjena već uz uključivanje mjera i sredstava te svih aktivnosti za izvršavanje postavljenih ciljeva u svim dijelovima sustava i procesa planiranja i praćenja jedinstveno, zavisno i istovremeno.

U posljednje vrijeme izuzetno je razvijeno područje upravljanja projektima koje je sigurno najsloženije s aspekta upravljanja. Ovdje se upravljanje zasnovano na upravljanju svim procesima smatra najboljim ali i najsloženijim, a pristup se temelji na upravljanju setom događaja-aktivnosti u skladu s postavljenim ciljevima, pravilima i vrijednostima. Proces je podloga za donošenje odluka u funkciji ostvarenja postavljenih ciljeva te omogućava bolje uspostavljanje vizije, strategije, strukture i resursa za postizanje uspjeha.

Na slici 4. je shematski prikazan opći model proizvodnog sustava za koje vrijedi ovo istraživanje pa će se barem dio poopćenja rješenja moći primijeniti na svaki sustav koji se uklapa u prikazani model.

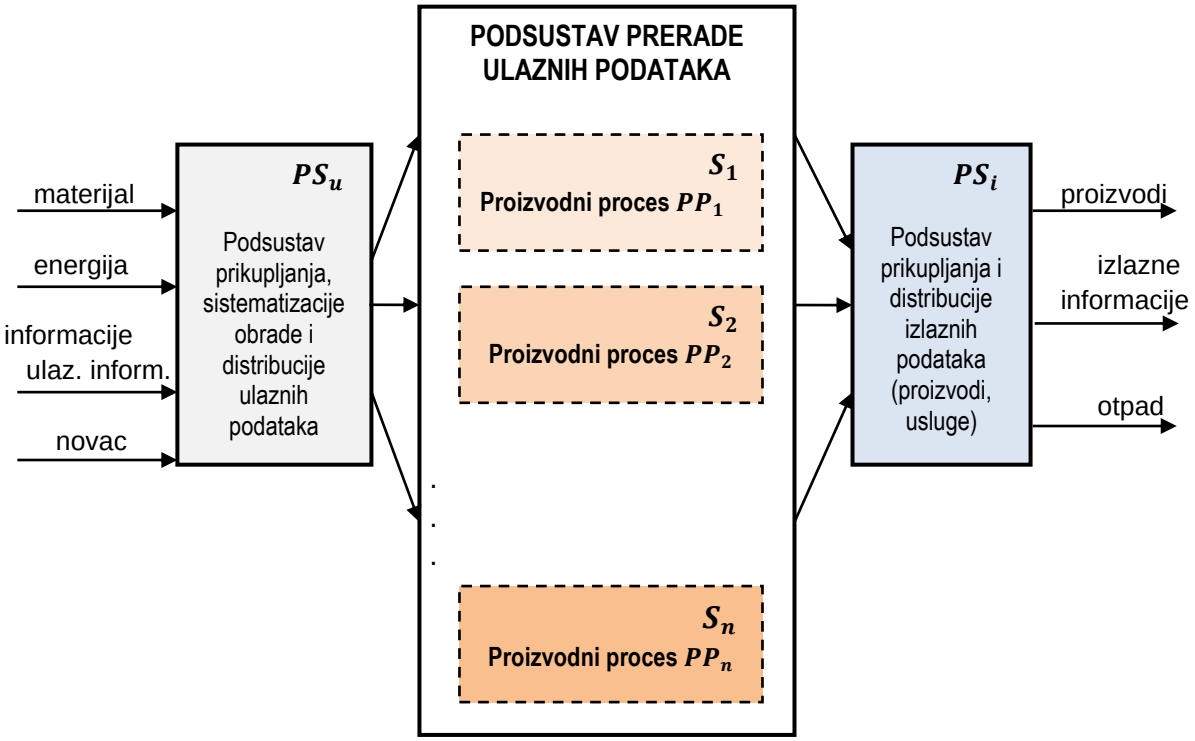

Slika 4. *Opći model proizvodnog sustava*

Ovdje se mora napomenuti da svaki proizvodni sustav ima svoje specifičnosti, kako po svojoj strukturi i ljudima tako i po okruženju u kojem se nalazi i prema kojem djeluje. Zbog toga se danas sve više obavljaju znanstvena istraživanja za specifične proizvodne sustave u posebnim uvjetima njihovog rada, a naročito obzirom na tip proizvodnje – pojedinačna ili masovna, način proizvodnje – za zalihe ili po narudžbi, te posebno obzirom na intenzitet promjena u njegovom okruženju.

Istraživanja u znanosti i praksi ukazuju na potrebu istraživanja modela i metodologije određivanja procesa operativnog planiranja i praćenja u smislu njegove optimizacije i projektiranja putem odabranih kriterija i mjerila u uvjetima naglih, velikih i brojnih promjena, s ciljem maksimalnog zadovoljenja potreba tržišta putem realizacije u proizvodnji, uz što veći mogući poslovni uspjeh poduzeća.

Utvrđena je potreba povezivanja stvarnih uvjeta u proizvodnom sustavu i njegovom okruženju putem procesa planiranja i praćenja proizvodnje uz primjenu metoda i tehnika optimizacije po odabranim kriterijima, za sve resurse sustava i njihovo raspoređivanje sukladno promjenama u okruženju.

U tom smislu se namjerava istražiti i predložiti konceptualni model i metode optimizacije procesa planiranja i praćenja proizvodnje putem utvrđivanja utjecajnih faktora na uspješnost planiranja i praćenja u datim uvjetima. To treba učiniti prema odabranim kriterijima i mjerilima, temeljem čega se može konkretizirati model i optimizirati proces planiranja i praćenja za neki promatrani proizvodni sustav.

2. PREGLED DOSADAŠNJIH ISTRAŽIVANJA

Prema opisu i obrazloženju izbora područja istraživanja u poglavlju 1.2. pregledano je više stotina naslova znanstvene literature i članaka objavljenih u zadnjih 15-tak godina od kojih je obrađeno 38 naslova čija se tematika veže za planiranje i praćenje proizvodnje i poslovanja s posebnim naglaskom na one naslove koji se bave optimiranjem proizvodnje u specifičnim uvjetima i odabranim kriterijima. Pregled obrađene znanstvene literature i znanstvenih članaka iz područja planiranja i praćenja daje se odvojeno, po redosljedu kako su obrađivani, a za sve se zatim iznose sintetske ocjene i zapažanja.

Uz navedeno, daje se i kratki pregled i ocjena dosadašnjih istraživanja i konkretnih projekata planiranja i praćenja u kojima je autor sudjelovao u nekoliko domaćih poduzeća.

2.1. Istraživanje znanstvene literature

Knjiga autora T.J.Coelli; D.S. Prasada Rao; C.J. O'Donnell i G.E.Battese, "An Introduction To Efficiency And Productivity Analysis", 2. edition, Springer, New York, 2005. [1] obrađuje analizu efikasnosti i produktivnosti proizvodnje po 4 osnovne metode: ekonometrijske procjene po modelima prosjeka sa analizom podataka i graničnom stohastičkom analizom te mjerenjem realizacije u proizvodnji uz usporedbu metoda i prijedlozima kompjuterskih programa koji se mogu koristiti u tu svrhu. Ujedno se daju upute za korištenje kompjuterskih programa SHAZAM, LIMDEP, TFPIP, DEAP i FRONTIER.

Naglasak je mjerenju produktivnosti i tehničke efikasnosti te produktivnosti po svim faktorima proizvodnje, uključujući mjerenje efikasnosti rada i kapitala te proizvodne funkcije kao odnosa izlaznog proizvoda prema ulaznom materijalu, radu i strojevima.

Obzirom na potrebe brzog donošenja odluka u proizvodnji, s vrlo malo vremena za kratka istraživanja ili dodatna pitanja autori T.E.Vollman; W.L.Berry i D.C.Whybark u knjizi "Manufacturing Planning And Control System", 4. edition, McGrow-Hill, 1997. [2] upućuju specijaliste na korištenje pojednostavljenih procjena ili preuzimanje rizika u funkciji smanjenja troškova i skraćenja vremena proizvodnje.

Daju se upute i rješenja za analize kojima se omogućava konkurentnost proizvodnje putem najnovijih spoznaja u području proizvodnje a što uključuje upravljanje nabavnim lancem, upravljanje prema zahtjevima tržišta, planiranje prodaje i proizvodnje, planiranje materijalnih zahtjeva (MRP-material requirements planning), planiranje resursa poduzeća (ERP-enterprise resource planning), kontrola proizvodnih aktivnosti, planiranje kapaciteta.

Kao najvažniji faktor naglašava se kupac i njegove potrebe i u tom smislu nužnost izlaženja u susret zahtjevima kupca da bi se došlo do uspjeha. Zbog toga se sve više primjenjuje sustav ERP kojim se integriraju sve aktivnosti i funkcije tvrtke, uključujući planiranje i praćenje proizvodnje (MPC-manufacturing planning and control) pri čemu se odlučivanje spušta na timove niže razine a efikasno upravljanje procesima kombinira se većim povezivanjem sa dobavljačima i kupcima.

Temeljem iskustva navećih svjetskih tvrtki, daju se primjeri primjene sustava ERP, tehnike upravljanja nabavnim lancem (SCM-supply chain management) za koordinaciju tokova metrijala i informacija, principi i značajke tehnike isporuke i proizvodnje na vrijeme (JIT-just-in-time) i njegov utjecaj na MPC te napredni koncepti i pristupi u planiranju prodaje, proizvodnje i nabave.

Hijerarhijsko planiranje proizvodnje razvijeno je kao originalna metoda za planiranje i raspoređivanje proizvodnih aktivnosti na način da se poboljšanom komunikacijom i koordinacijom uzduž svih nivoa planiranja smanje troškovi proizvodnje. Autor Tan C. Miller u svojoj knjzi "Hierarchical Operations And Supply Chain Planning", Springer, New York, 2002. [3] prikazuje primjenu hijerarhijskog planiranja nabavnog lanca (SCM) gdje uključuje proizvodnju, isporuku, skladištenje, transport, upravljanje zalihama i predviđanja. Daju se algoritmi za jednostavne algebarske kalkulacije za modele matematičke optimizacije te povezivanje mjerenja za efikasnost SCM u sustav mjerenja efikasnosti cijele tvrtke.

U dijelu strateškog planiranja utvrđuju se kapaciteti pogona i skladišta te transportni putevi kao osnova za logističke odluke, gdje se uključuju rizici koji su u strateškom planiranju veći a profit se planira na dugoročnoj osnovi.

Taktičko planiranje za 1 godinu obuhvaća kvartalno planiranje kapaciteta, radne snage, načine distribucije i transport, a operativno planiranje i raspoređivanje obavlja se za svaki mjesec dnevno ili tjedno te utvrđuju odluke koje se moraju donositi po pojedinim nivoima planiranja. Također se razrađuju tehnike planiranja segmenata poduzeća – prodaja, nabava, proizvodnja, skladištenje i transport.

Uz primjenu kriterija minimalnih troškova odvojeno se razrađuje planiranje na 4 nivoa:

a. na nivou tvrtke – godišnji plan, uz primjenu cjelobrojnog programiranja
b. sezonski – po pogonima, za svaki proizvod, uz primjenu linearnog programiranja
c. mjesečno – po grupama proizvoda i svakom pogonu, detaljno
d. terminiranje – po svakom proizvodu, mjesečno po pogonima

Knjiga autora Michael L. Pinedo, "Planning And Scheduling In Manufacturing And Services", Springer, New York, 2004. [4] bavi se primjenom planiranja i raspoređivanja u području proizvodnje i usluga kao formama za donošenje odluka u tvrtkama koje koriste analitičke tehnike i heurističke metode u dodjeljivanju ograničenih resursa. Pokriva se pet područja proizvodnje: planiranje projekta, planiranje radionica-pogona, planiranje u fleksibilnim montažnim sustavima, planiranje u ekonomskim sustavima i planiranje u nabavnim lancima dok se u području usluga obrađuju četiri područja: rezerviranje i raspoređivanje, raspoređivanje turnusa, planiranje i raspoređivanje u transportu te planiranje radne snage.

Autor se bavi planiranjem projekata primjenom tehnika CPM i PERT uz primjenu kriterija vremena i troškova, a prilikom optimizacije proizvodnje primjenjuje tehnike linearnog i nelinearnog programiranja, dinamičkog programiranja i heurističke metode te selektivno planiranje.

U knjizi "Production Economics", Krieger Publishing Co., Melbourne, Florida/US, 2007. [5] autor Steven T. Hackman bavi se odgovorima na pitanja na koja bi se ekonomisti proizvodnje fokusirali na bazi procjena – kako da se tvrtke uspoređuju s konkurencijom i da li poboljšavaju svoje kapacitete. Istovremeno, obrađuje se optimizacija resursa što je interes inženjera u proizvodnji uz detaljno definiranje tehnoloških postupaka i raspoređivanje tehnoloških operacija s rokovima te davanje rješenja za pronalaženje dodatnih kapaciteta.

Autor daje rješenja za istovremenu optimizaciju resursa i ekonomičnost proizvodnje i inzistira na njihovoj istovremenosti.

Autori Massimiliano Caramia i Paolo Dell' Olmo u knjizi "Effective Resource Management In Manufacturing Systems: Optimization Algorithms For Production Planning", Springer, New York, 2006. [6] daju rješenja za organiziranje i upravljanje funkcijama u proizvodnom sustavu i kako primijeniti grube metode za postizacije efikasnog raspoređivanja resursa u dinamičkom okruženju, s posebnim naglaskom na određivanje nivoa resursa, veličinu strojeva i njihov raspored te optimizaciju troškova u planiranju i raspoređivanju proizvodnje.

Polazeći od opisa proizvodnog sustava, pristupa njegovom upravljanju i praćenju, autori daju algoritme za raspoređivanje resursa i rješavanje problema balansiranja i opterećivanja brojnih strojeva u slučaju kada narudžbe koje stižu trebaju biti raspoređene u postojeći plan, koristeći se pri tome meta-heurističkim pristupom. Pri tome se navode rješenja niveliranja resursa i metode za profiliranje resursa u planu na način da se istovremeno razmatraju tri objektivno različite funkcije – minimizacija raspona, vrh korištenja resursa i balansiranje dodijeljenih resursa. Daje se novi heuristički algoritam koji može biti primijenjen za on-line scenarije kao i u dinamičkom okruženju, a koji daju bolje rezultate od do sada poznatih što je potvrđeno komparativnom analizom.

U knjizi autora Stefan Voss; David L. Woodruff; "Introduction To Computational Optimization Models For Production Planning In A Supply Chain", Springer, New York, 2002. [7] obrađuje se simbolično modeliranje optimizacije za planiranje proizvodnje gdje su slične paradigme MRP i MRP II korištene kao odskočne točke. Poznati modeli planiranja MRP i MRP II proširuju se na više načina u softificirane modele za upravljanje nabavnim lancem (SCM).

Autori Robert M. Tork i Patrick J. Cordon u svojoj knjizi "Operational Profitability", John Wiley&Sons, New York, 2002. [8] razrađuju brojne načine mjerenja operativne profitabilnosti proizvodnje uz analizu upravljanja financijskim pokazateljima, analizu toka novca i mjera efikasnosti proizvodnih operacija. Posebno se razrađuju metode redukcije troškova proizvodnje te određivanje ciklusa prognoziranja.

Distribuirane proizvodne mreže tema su knjige autora Pierluigi Argonato i njegovih suradnika, "Production Planning In Production Networks: Models For Medium and Short-term Planning", Springer, New York, 2008. [9], kao strukture koje su u mogućnosti osigurati organizacijsku agilnost i efikasnost potrebnu na globalnom tržištu. Pri tome se pojavljuju dva pristupa upravljanja kompleksnim distribuiranim proizvodnim mrežama – centralizirani gdje planer ima sve informacije potrebne za donošenje odluka i decentralizirani u kojem svaki subjekt ima potrebne informacije i znanja za donošenje autonomnih odluka u planiranju, a zajednički se cilj ostvaruje suradnjom ljudi uključenih u proizvodnu mrežu.

Autori daju rješenja sa strateškog, taktičkog, organizacijskog i operativnog stajališta putem novih metodologija dogovora o kapacitetima, rasporedu i podjeli rada u proizvodnim mrežama. Tu se javljaju tri glavna problema – kako utvrditi kapacitete za duže vremensko razdoblje, kako dodijeliti kapacitete u srednjem vremenu planiranja i kao rasporediti opterećenje proizvodnje za kratko vremensko razdoblje planiranja.

Predloženi pristup je zasnovan na algoritmima pregovaranja u multi-agentskim mrežama, a uspoređivan je sa klasičnim centraliziranim pristupom uz metodologiju diskretne simulacije događaja po kriteriju efikasnosti.

U knjizi "Design And Analysis Of Lean Production System", John Willey& Sons, USA, 2001. [10] autora Ronald G. Askin i Jeffrey B. Goldberg obrađuju se diskretni dijelovi proizvodnog sustava na bazi ključnih funkcija i komponenti proizvodnog sustava i njegovih osnovnih načela. Opisuje se standardno hijerarhijsko odlučivanje s posebnom obradom metoda i modela za predviđanje, strateško planiranje, oblikovanje nabavnog lanca, pojedinačno planiranje, sustavima praćenja, hijerarhijsku koordinaciju, lean-proizvodnju, raspoređivanje i praćenje po pogonima, a matematički modeli zasnovani su na kriterijima minimalnih vremena i troškova.

U knjizi "Projektni menadžment – upravljanje razvojnim promjenama", Ekonomski fakultet u Rijeci, 2010. [11], autor Zdravko Zekić obrađuje pretpostavke uspješnog upravljanja poslovanjem suvremenog poduzeća kao sustavom simbioze stabilnosti i kaosa u uvjetima sve veće turbulencije okoline, naročito potaknute ubrzanim znanstveno-tehnološkim razvojem od polovice prošlog stoljeća, koje su uvjetovale da se u novije vrijeme projektima kao modelima upravljanja razvojnim promjenama konačno dade pripradajuće mjesto i u ekonomskoj teoriji.

Projektni menadžment, kao proces sustavnog ciljno integriranog vođenja raspoloživih ljudskih potencijala i logističkih tokova ograničenih materijalnih, financijskih i informacijskih resursa kroz procese projektne realizacije u svrhu efektivnog i efikasnog ostvarivanja unaprijed postavljenih projektnih ciljeva u pogledu obuhvata troškova, vremena i kvalitete izvedbe, a koji zadovoljavaju potrebe i očekivanja korisnika projektnog proizvoda bolje od konkurencije, predstavlja model uspješnog upravljanja dinamičkom optimizacijom poslovanja i razvoja poduzeća. Početno razvijena operativna dimenzija upravljanja projektima sustavno se transformira u razvijeni sustav projektnog upravljanja poslovanjem i razvojem poduzeća, razvijajući strategijsku dimenziju projektnog menadžmenta.

2.2. Istraživanje znanstvenih članaka

U članku autora C.A.Soman; D.P.Van Donk; G.J.C.Gaalman, "Capacitated Planning And Scheduling For Combined Make-to-order And Make-to-stock Production In Food Industry", International Journal Of Production Economics, Vol.108, pages 191-199, 2007. [12] obrađuje se konceptualno planiranje za slučaj kada je potrebno kombinirati planiranje proizvodnje po narudžbi (MTO-make-to-order) s planiranjem proizvodnje za zalihe (MTS-make-to-stock). Rad se zasniva na primjeru tvrtke iz prehrambene industrije sa 230 proizvoda i ograničenim kapacitetima, uz primjenu heurističke metode u rješavanju tog problema, s posebnim naglaskom na srednjeročnom i kratkoročnom planiranju proizvodnih serija uz prethodno analitičko odlučivanje.

Autori L.C.Hendry i B.G.Kingsman u članku "Production Planning System And Their Applicability To Make-to-order Companies", European Journal Of Operational Research, Vol.40, pages 1-15, 1989. [13] obrađuju problem planiranja proizvodnje za zalihe (MTS-make-to-stock) koji je još dominirao u to vrijeme, a problemima planiranja u tvrtkama koje su radile po narudžbama (MTO-make-to-order) posvećivalo se manje pažnje iako se modeli za ovaj drugi slučaj mogu primijeniti i za prvu grupu tvrtki.

U članku se identificiraju razlike za ta dva navedena slučaja i što se od spoznaja iz planiranja za zalihe može primijeniti za slučaj planiranja po narudžbama, uključujući način planiranja proizvodnje, praćenje zauzetosti kapaciteta i izvršenje rokova, uz diskusiju o pristupima MRP II, OPT i JIT u slučaju sektora proizvodnje po narudžbi.

Članak autora G.Zapfel i H.Missbaner, "New Concepts For Production Planning And Control", European Journal Of Operational Research, Vol.67, pages 297-320, 1993. [14] daje usporedbu starijih metoda planiranja i praćenja proizvodnje putem računala (PPC-production planning and control) zasnovanih na poznatoj MRP logici u odnosu na nove koncepte PPC za praktičnu primjenu, a u što spada MRP II, OPT, JIT i dr., uključujući modele operativnog istraživanja (OR) relevantne za navedene nove koncepte planiranja.

Autori J.Olhanger; M.Rudberg i J.Vikner u članku "Long-term Capacity Management: Linking The Perspectives For Manufacturing Strategy And Sales And Operations Planning", International Journal Of Production Economics, Vol.69, pages 215-225, 2001. [15] polaze od činjenice da učinkovitost svake tvrtke ovisi o upravljanju kapacitetima za duže vremensko razdoblje.

To utječe na troškove, brzinu isporuke, pouzdanost i fleksibilnost proizvodnog sustava pa je u proizvodnoj strategiji kapacitet važna kategorija za odlučivanje, uz bavljenje proširenjem kapaciteta i reduciranjem dugoročnih promjena u nivoima potražnje. Planiranje prodaje i djelovanja (S&OP-sales and operations planning) je dugoročno planiranje nivoa proizvodnje u okviru planiranja i praćenja proizvodnje.

U domeni planiranja prodaje i aktivnosti, planiranje resursa se koristi za određivanje prikladnih nivoa kapaciteta zbog podržavanja plana proizvodnje. Mijenjanjem različitih parametara te promjenama potražnje i nabave autori uspoređuju različite perpektive proizvodne strategije i planiranja prodaje i aktivnosti te daju odgovarajuće modele rješenja.

U članku "Primjena Lean koncepta u proizvodnoj djelatnosti", Tehnički vjesnik, br.17 (3) stranice 353-356, 2010. [16] autori N. Štefanić; N. Gjeldim i T. Mikac razmatraju slučaj kada velika konkurencija i stalne promjene u zahtjevima tržišta traže od poduzeća stalnu promjenu i poboljšanje poslovanja, pri čemu je za proizvodna poduzeća jako je važno zadržati poslovne procese efikasnim, na način da ih se kontinuirano poboljšava. U ovom je radu prikazan procesni pristup upravljanja proizvodnjom te su dane osnove Lean proizvodnje. Kao jedan od efikasnih Lean alata za analizu procesa proizvodnje pokazao se alat Mapiranje toka vrijednosti. Na primjeru iz prakse pokazano je kako ovaj alat može biti koristan u analizi gubitaka tj. rasipanja u proizvodnom procesu.

U članku autora R.Lujić; T.Šarić; G.Šimunović, "Primjena ekspertnog sustava pri određivanju klase prioriteta radnog naloga u pojedinačnoj proizvodnji", Tehnički vjesnik, br.14(1,2), stranice 65-75, 2010. [17] se pokazuje kako se analiziranjem stanja u proizvodnim poduzećima otkriva kako je u proizvodnji često prisutno neispunjenje obveza prema krajnjem kupcu, kašnjenje u rokovima isporuke, narušavanje ugleda firme i/ili plaćanje visokih penala. Uz neadekvatan model terminiranja koji često puta nema mogućnost izrade varijanti planova kao jedan od najvažnijih uzročnika kašnjenja navedeni su neadekvatni i neprimjenjivi modeli prioriteta. Definiran je pojam prioriteta i predložen novi model klasa prioriteta za pojedinačnu i maloserijsku proizvodnju, baziran na ekspertnim sustavima. Predloženi model u odnosu na postojeća pravila prioriteta uvodi niz novih parametara, ne samo iz službe tehnologije, već i iz službi prodaje i nabave. Klase prioriteta riješene su na razini radnih naloga i uzimaju u obzir različite vrste atributa ali i njihovih vrijednosti.

Autori Martin J. Land i Gerard J. C. Gaalman u članku "Production Planning And Control in SMEs: Time For Change", Production Planning & Control Journal, 7/2009., pages 548-558[18] se bave konceptima postojećeg planiranja i praćenja u malim i srednjim tvrtkama koje rade po narudžbama kupaca (MTO) putem proučavanja primjera u nekoliko takvih tvrtki. Analiza pokazuje da se značajna proporcija zajedničkih problema planiranja i praćenja proizvodnje (PPC-production planning and control) može pripisati ograničenom broju točaka odlučivanja u protoku narudžbi, a autori su utvrdili da se gubici u izvedbi mogu predvidjeti prije realizacije u pogonu. Utvrđeno je da u predproizvodnoj fazi postoje dva područja problema – neadekvatno planiranje kapaciteta u odnosu na odluke prodaje i nekontrolirano kašnjenje u inženjeringu, a ta su područja do sada slabo istraživana.

U članku autora J. Alfaro; A. Ortiz; R. Poler, "Performance Measurement System For Business Processes", Production Planning & Control Journal, 8/2007., pages 641-654 [19] daje se odgovor kako utvrditi na kojem nivou i u kojem opsegu su u nekom sustavu zadovoljni sa svojim ciljevima putem predstavljanja sustava koji su nazvali sustav mjerenja izvedbe u poslovnim procesima (PMS-BP – performance measurement system for business processes) na način da se mjeri izvedba putem indikatora ili parametara na svim nivoima tvrtke, a za što se daje metodologija, izgradnja i struktura mjerenja izvedbe. Procesi se analiziraju putem različitih tipova grafova koji pokazuju stanje i povezanost različitih elemenata mjerenja izvedbe po različitim nivoima tvrtke.

Autori John J. Kanet i Martin Stoesslein u članku "Integrating Production Planning And Control: Towards A Simple Model For Capacitated ERP", Production Planning & Control Journal, 3/2010, pages 286-300 [20] daju jednostavnu varijaciju planiranja resursa poduzeća i planiranja potreba materijala (ERP/MRP) nazvanu "Capacitated ERP" koji uzima u obzir resurse kapaciteta prije širenja zahtjeva na niži nivo komponenata i što se uključuje u tipični SCM software za takve tvrtke.

Članak autora Philip G. Moscoso, Jan C. Fransoo, Dieter Fisher, "An Empirical Study on Reducing Planning Instability in Hierarchical Planning System", Production Planning & Control Journal, 4/2010, pages 413-426 [21] doprinos je empirijskom i teoretskom razvoju planiranja u uvjetima nestabilnosti za tvrtke koje imaju poteškoća u postizanju rokova traženih od strane kupaca, gdje planeri na različitim nivoima hijerarhijskog planiranja moraju preraspoređivati već otvorene naloge i davati im nove rokove.

Kao rješenje se daje napredni sustav planiranja (APS-advanced planning system) koji uključuje centraliziranje odluka u planiranju s minimalnim promjenama rokova za tekuće naloge u proizvodnji uz primjenu metode oponašanja, uz uvjet stabilnosti ljudskog i organizacijskog faktora.

Autori Gyu C. Kim, Marc J. Schniederjans i Stacy S. Kim u članku "Simulation Study of Availability Management in a Make-to-order Manufacturing Environment for a Differentiated Order System", Production Planning & Control Journal, 1/2010, pages 47-49 [22] analiziraju diferencirani sustav narudžbi za proizvodne tvrtke u kontekstu proizvodnje po narudžbi (MTO). Kreiran je simulacijski model za analize različitih scenarija koji uključuju razne veličine varijabli narudžbi, rokova i stopa narudžbi i prikazuje kako različiti oblici prilagodbe mogu biti iskorišteni za upravljanje procesom dostupnosti narudžbi.

Članak autora Min Zhen, Tariq Masood, Aysin Rahimifard, Richard Weston, "A Structural Modelling Aproach to Simulating Dynamic Behaviours in Complex Organization", Production Planning & Control Journal, 6/2009, pages 496-509 [23] istražuje slučaj sustavnog pristupa modeliranja kompleksne organizacije zasnovan na simulacionom modeliranju (SM) u svrhu donošenja odluka za proizvodnju te određivanje politike planiranja i praćenja proizvodnje.

Članak "Procedure for Reducing the Risk of Delayed Deliveries in Make-to-order Production", Production Planning & Control Journal, 4/2009, pages 332-342 [24] autora H. Stefansson, P. Jensson i N. Shah se bavi planiranjem i raspoređivanjem proizvodnje koja se radi po narudžbi i koja se odvija u vrlo nepredvidljivom i konkurentnom okruženju što zahtjeva visok nivo usluga i fleksibilnost te se mora se ponuditi proizvod koji nije skup i ima kratak rok isporuke, pa je planiranje i raspoređivanje vrlo teško a bitno je za uspjeh. Autori razvijaju sustavnu metodu za planiranje i raspoređivanje u uvjetima neizvjesnosti, a da planovi budu efikasni i pouzdani s reduciranim rizikom kašnjenja u isporukama gdje se tretira nekoliko izvora neizvjesnosti uz variranje uvjeta potražnje.

Autori Jorge E. Hernandez, Josefa Mula i Francisco J. Ferriols u članku "A Reference Model for Conceptual Modelling of Production Planning Processes", Production Planning & Control Journal, 8/2008, pages 725-734 [25] daju referentni model za konceptualno modeliranje procesa planiranja proizvodnje s ciljem minimiziranja ukupnih troškova proizvodnih planova putem analize ulaza, izlaza, procesa i podprocesa kako bi planeri i istraživači u konkretnim slučajevima mogli razviti modele za vlastite procese planiranja proizvodnje.

Simulacija se kao tehnika koristi od početka 60-tih godina prošlog stoljeća i udružena sa snagom računala sve više se koristi se kao podržavajući alat za proizvodnju u smislu smanjenja troškova pa se postavlja pitanje optimalnog korištenja tog alata u rutinskom smislu.

U tu svrhu autori Mohammed M. Al Durgham i Mahmoud A. Barghash u članku "A Generalised Framework for Simulation-based Decision Support for Manufacturing", Production Planning & Control Journal, 5/2008, pages 518-534 [26] razvijaju okvir za primjenu simulacije za proizvodnju (SAFM – simulation application framework for manufacturing) gdje se naglašava odnos između različitih područja odlučivanja i određuje zadatak za korištenje simulacije kao podrške za sustavno odlučivanje. Osnovne komponente rješenja su proizvodne strategije, raspored opreme, rukovanje materijalom, raspoređivanje, proizvodni procesi i resursi, a rješenje SAFM se pokreće i kontrolira prema upravljačkim strategijama i prioritetima.

U članku autora R. Affonso, F. Marcotte, B. Grabot, "Sales and Operations Planning: the Supply Chain Pillar", Production Planning & Control Journal, 2/2008, pages 132-141 [27] smatra se da je planiranje prodaje i izvedbe (S&OP) ključan proces za osiguranje spoznaja u nekom poduzeću i podržava proces odlučivanja kojim se koordiniraju različite funkcije u tvrtki ili između tvrtki u okruženju nabavnog lanca. Za razliku od većine S&OP modela koji su orijentirani na prodaju, proizvodnju i opremu, ovdje se prelaže širi S&OP model koji je izgrađen sa tri razine – prodaja, izvedba, nabava,a što omogućava bolju potporu integraciji u tvrtki ali i sa tvrtkama u nabavnom lancu SC, što pokazuju i rezultati dobiveni oponašanjem.

Kako je na dinamičkom i konkurentnom tržištu zanimljiva važnost fleksibilnosti sustava u mreži nabavnog lanca (SC), u ovom članku autora Domenico Aprile, A. Claudio Garavelli i Ilaria Giannoccaro, "Operations Planning and Flexibility in a Supply Chain", Production Planning & Control Journal, 1/2005, pages 21-31 [28] razmatraju se dva glavna aspekta – fleksibilnost procesa i fleksibilnost logistike u skladu sa vezama između dobavljača, proizvođača i tržišta. U tu svrhu predlaže se nekoliko konfiguracija nabavnog lanca, u skladu sa različitim stupnjevima procesa i logističke fleksibilnosti čiji se efekti istražuju putem izvedbe operativnog planiranja u uvjetima neizvjesnosti kapaciteta i različite potražnje, a zatim se radi optimizacija izvedbe nabavnog lanca SC za svaku konfiguraciju nabavnog lanca.

Članak "Managing Strategy through Business Processes", Production Planning & Control Journal, 4/2003, pages 309-326 [29] autora Nuran Acur i Umit Bititci bavi se procesom dinamičkog strateškog upravljanja vrednujući postojeće modele, metodologije, alate i tehnike gdje se zaključuje da niti jedan pristup ne zadovoljava sve zahtjeve.

Zbog toga je razvijen novi model PROPHESY, procesno orijentiran, u kojem se razvijaju horizontalne strategije koje imaju za cilj koordinirati poslovne procese i razvijati ciljeve koji potiču raspodjelu resursa i znanja.

Sustav mjerenja u upravljanju promjenama s primjenom simulacijskih igara u promjenama procesa, tema je članka autora Tapani Taskinen, "Improving Change Management Capabilities in Manufacturing: From Theory to Practice", Production Planning & Control Journal, 2/2003, pages 201-211 [30] gdje se testira sustav mjerenja u upravljanju promjenama u praksi na dva konkretna slučaja. Sugerira se uravnoteženo mjerenje upravljanja promjenama i upravljanja proizvodnim aktivnostima.

Autor Jatinder N. D. Gupta u članku "An Excursion in Scheduling Theory: An Overwiew of Scheduling Research in the Twentieth Century", Production Planning & Control Journal, 2/2002, pages 105-116 [31] daje pregled istraživanja teorije raspoređivanja u 20. stoljeću za različite probleme raspoređivanja u proizvodnji i mogućih pristupa koji to mogu riješiti, pri čemu se prikazuje prijelaz u teoriji i praksi svake paradigme. Predlaže se iterativni proces raspoređivanja kao produženje postojećih paradigmi u rješavanju praktičnih problema raspoređivanja.

U članku autora Siddharth Mestry, Purushothaman Damodaran, Chin-Sheng Chen, "A Branch and Price Solution Approach for Order Acceptance and Capacity Planning in Make-to-order Operations", European Journal Of Operational Research, Vol.211/2011, pages 480-495 [32] polazi se od pretpostavke da se selektivnim prihvaćanjem narudžbi kupaca i istovremenim planiranjem kapaciteta aktivnosti u slučaju rada po narudžbama kupaca (MTO) mogu efikasno voditi i dugoročno osigurati prihvatljivi profit. Za slučaj kad postoje narudžbe kupaca s definiranim rutama procesa, vremenima procesa i prodajnim cijenama s ograničenim resursima, mogu se prihvaćati samo neke narudžbe.

Putem predloženog programa MILP predlaže se dodavanje operativnog managera koji će odlučivati koje nove narudžbe prihvatiti i kako rasporediti kapacitete da se ostvari maksimalni profit uz korištenje algoritma zasnovanog na Dantzig-Wolfe-ove razgradnje problema na podprobleme za koje je predloženo efikasno rješavanje uz primjenu računalne analize.

U članku "Advanced Supply Chain Planning with Mixtures of Backorders, Lost Sales, and Lost Contract" European Journal Of Operational Research, Vol.181/2007, pages 168-183 [33] autor Emmett J. Lodree, Jr. istražuje sustav nabavnog lanca (SC) u kojem se dobavljači pripremaju za sezonu prodaje stvarajući zalihe kalkulirajući sa gubitkom prodaje i ugovora. Optimalno rješenje je u zatvorenoj formi za slučaj eksponencijalne distribucije potražnje.

Autori Guisen Xue, O. Felix Offodile, Hong Zhou i Marvin D. Troutt u svom članku "Integrated Production Planning with Sequence-dependent Family Setup Times", International Journal Of Production Economics, Vol.131/2011, pages 674-681 [34] predlažu integrirani model optimizacije skupnog planiranja proizvodnje (APP – aggregate production planning) i slične probleme planiranja u hijerarhijskom planiranju proizvodnje (HPP) pri čemu se daje optimalni plan za svaki proizvod u svakom periodu, zajedno s optimalnim slijedom palete proizvoda u ukupnom planskom perioda, a kao kriterij se uzima ušteda troškova.

Članak "Modeling and Simulation of Order-driven Planning Policies in Build-to-order Automobile Production", International Journal Of Production Economics, Vol.131/2011, pages 183-193 [35] autora Thomas Volling i Thomas S. Spengler bavi se modeliranjem i simulacijom politika planiranja u automobilskoj industriji koja teži boljoj sinhronizaciji svoje proizvodnje s potražnjom na tržištu za što se traži nova paradigma u planiranju proizvodnje. Rješenje se zasniva na analizi planiranja vođenog po narudžbama u kojem se obuhvaća odvojeni kvantitativni model za obećavajuće narudžbe i glavni plan proizvodnje koji se modeliraju i vrednuju u dinamičkom postavljanju a vrednovanje se vrši simulacijskom analizom.

Autor Ely Laureano Paiva se u članku " Manufacturing and Marketing Integration from a Cumulative Capabilities Perspective", International Journal Of Production Economics, Vol.126/2010, pages 379-386 [36] bavi integracijom proizvodnje i marketinga i vrednovanjem odnosa u tom slučaju, prioritetima u upravljanju i poslovnim rezultatima za što je obavljeno istraživanje u 99 tvrtki iz različitih industrija i gdje je dokazano da integracija proizvodnje i marketinga, kao i upravljački prioriteti, pozitivno utječu na poslovne rezultate.

U članku " Models for Production Planning under Uncertainty: A Review", International Journal Of Production Economics, Vol.103/2006, pages 271-285 [37] autori J. Mula, R. Poler, J. P. García-Sabater i F.C. Lario daju pregled modela planiranja proizvodnje u uvjetima neizvjesnosti u razdoblju 1984.-2004. godine koji su pokazali velik napredak u tom razdoblju. Razmatraju se svi modeli po grupama – konceptualni modeli, analitički modeli, modeli umjetne inteligencije te simulacijski modeli gdje se naglašava potreba daljnjeg razvoja simulacijskih modela za uvjete neizvjesnosti.

U članku autora Zdravko Zekić, "Logistički model dinamičke optimizacije poslovanja poduzeća", Ekonomski pregled, Vol. 52/2001 [38] polazi se od činjenice da je uspješnost poslovanja suvremenog poduzeća sve manje ovisna o efikasnosti obrade velikih količina sirovina i materijala a sve više ovisi o efikasnosti upravljanja materijalnim, financijskim i informacijskim tokovima putem usklađivanja ponude sa zahtjevima potražnje. U tu svrhu glavna pretpostavka uspješnosti je upotreba modela i pomagala koji simulacijom unaprijed pokazuju rezultate odluka.

Posebno se ukazuje na spoznaju da u suvremenom turbulentnom okruženju nije cilj optimizirati stanje poduzeća – dobit ili profitnu stopu, već je svrha optimizirati fleksibilnost i adaptibilnost kao pokazatelje njegove dinamičke optimizacije poslovanja. U tom smislu samo stalni kontakt s ulaznom i izlaznom okolinom, dinamičko prilagođavanje potrebama kupaca i međukorporacijska suradnja jedini su put za opstanak i razvitak poduzeća na globaliziranom tržištu.

2.3. Sintetski pregled znanstvenih istraživanja

Pregledom i istraživanjem velikog broja znanstvene literature i članaka iz područja operativnog planiranja i praćenja, od prvih godina vlastitog istraživanja pa sve do danas, mogu se utvrditi spoznaje, činjenice i ocjene istraživanja kako slijedi:

01. Razvijeni su modeli hijerarhijskog planiranja i praćenja – strateški, taktički i operativni – pri čemu se planovi povezuju, a taktički planovi se razrađuju na nivou kvartala za proizvodne kapacitete, radnu snagu i logističke funkcije, uz razradu kriterija i algoritama za odlučivanje kao što su algebarske kalkulacije i matematički modeli optimizacije [3, 4], 9, 34]
02. Veliki dio istraživanja bavi se planiranjem po metodi SCM (Supply Chain Management) gdje se planiranjem i praćenjem obuhvaća više funkcija poduzeća, od dobave materijala do odnosa sa kupcima proizvoda, a posebno se naglašava i razvijaju modeli istovremenog planiranja i praćenja proizvodnje i marketinga i gdje se primjenom simulacije dinamičkih ponašanja modelira strukturni pristup u složenim organizacijama [2, 3, 4, 20, 28]

03. U proces planiranja i praćenja proizvodnje PPC (Production Planning and Control) uključuju se rješenja koja omogućuju fleksibilnost poduzeća prema promjenama i zahtjevima u okruženju pa se kombinira planiranje proizvodnje za zalihe i za poznatog kupca, pri čemu se posebna važnost daje terminiranju proizvodnje [12]
04. U zadnje vrijeme sve više su prisutna istraživanja i konkretni modeli rješenja planiranja i praćenja proizvodnje po narudžbi MTO (Make-to-order), za poznatog kupca ili pojedinačnu proizvodnju a u uvjetima nesigurnosti i promjenjive potražnje pri čemu se primjenjuju metode simulacije za različitu pojavnost narudžbi i rokove isporuke, uz određivanje procedure za smanjenje rizika u kašnjenjima isporuka i nestabilnosti hijerarhijskog sustava planiranja [13, 22, 23, 24, 35]
05. Utvrđuje se potreba decentraliziranog dinamičkog upravljanja na nižim, operativnim razinama za sve procese poduzeća te koordinacija tih procesa putem planiranja i praćenja [2, 3, 9, 29]
06. Veliki broj istraživanja planiranja i praćenja pokazuje da je neophodno stalno unapređivati proizvodnju primjenom Lean koncepta zbog što boljeg prilagođavanja tržištu i u odnosu na konkurenciju [10, 16]
07. U cilju povećanja efikasnosti poduzeća sve je veća zastupljenost planiranja svih resursa poduzeća (ERP- Enterprise Resource planning), i proizvodnje (MRP – Manufacturing Requirement Planning), uz primjeravanje potrebama kupaca, te brzo donošenje odluka na način da se one donose na nižim razinama poduzeća kako bi se smanjili troškovi i vremena realizacije proizvodnje [2, 7, 14, 16, 17, 18, 20, 27]
08. Utvrđuju se dva glavna pristupa planiranju – centralizirano i decentralizirano – pri čemu se posebno razmatraju tri glavna problema – utvrđivanje raspoloživih kapaciteta za duži vremenski period (za godinu dana), dodjeljivanje kapaciteta u srednjem vremenu planiranja (kvartalno) i raspoređivanje opterećenja proizvodnje za kraća vremenska razdoblja (unutar jednog mjeseca) [2, 3, 8]
09. Sve su prisutnija istraživanja s istovremenim tretiranjem optimizacije resursa i ekonomičnosti proizvodnje s raspoređivanjem resursa proizvodnje sukladno dinamici promjena u okruženju uz optimizaciju troškova, povezivanje procesa proizvodnje, prodaje i nabave usklađivanjem njihovih planova te održavanje stalnih veza sa dobavljačima i kupcima [3, 5, 6]
10. U radovima koji daju pregled i analizu istraživanja u području planiranja i praćenja proizvodnje utvrđen je premali broj istraživanja i rješenja koja bi u većoj mjeri povezala postojeće modele planiranja i praćenja proizvodnje sa stvarnim zbivanjima i potrebama.

To se posebno na slučajeve u praksi kada je prisutna nestabilnost i intenzivne promjene u okruženju [21, 31, 37]

11. Obzirom na stupanj primjene i zadovoljenja potreba u planiranju i praćenju proizvodnje, očekuje se više istraživanja i znanstvenih radova u tom području koji će u većoj mjeri primjenjivati metode i tehnike simulacije s iterativnim ponavljanjem procesa planiranja i praćenja s ciljem dolaženja do optimalnih rješenja u datim uvjetima, pa se modeliranje procesa planiranja i praćenja proizvodnje obzirom na njene ulaze i izlaze smatra novim pravcem intenzivnih radova i istraživanja u budućnosti [25, 26, 31, 37]
12. U okviru brojnih modela planiranja i praćenja proizvodnje, kako za uobičajne tako i za specifične uvjete u proizvodnji i njenom okruženju, optimizacija planova proizvodnje najčešće se vrši po kriterijima minimalnih troškova i utroška vremena te maksimalnog profita i iskoristivosti kapaciteta putem primjene linearnog programiranja, dinamičkog programiranja, teorije igara i simulacije uz stohastički i heuristički pristup [1, 3, 4, 5, 6, 7, 8, 9, 13]
13. Ukazivanje na neophodnost fleksibilnosti poduzeća kod promjena u poduzeću i okolini zahtjevima sa tržišta uz traženje optimuma ukupnog procesa poslovanja i optimalnog ponašanja poduzeća u uvjetima dinamičkih promjena [11, 15, 28, 36, 38]
14. U istraženim znanstvenim radovima mjerenje efikasnosti proizvodnje najčešće se vrši putem mjerenja i uspoređivanja ulaza i izlaza proizvodnje putem raznih algoritama zasnovanim najčešće na troškovima, vremenu proizvodnje, iskoristivosti kapaciteta, produktivnosti i profitu uz primjenu linearnog programiranja, dinamičkog programiranja, stohastičkim i heurističkim pristupima i u znatnoj mjeri uz korištenje simulacije, a uz to se mjeri operativna profitabilnost te vrši analiza tokova novca i operacijske efikasnosti [1, 4, 5, 6, 8]

Temeljem izvršenog istraživanja u znanstvenoj literaturi i člancima može se donijeti nekoliko zaključaka i ocjena:

a. mali broj istraživanja o upravljanju-organizaciji putem vođenja procesa, već dominiraju modeli izrade optimalnih planova proizvodnje, redosljeda lansiranja i realizacije radnih naloga i sl.

b. većina istraživanja su usmjerena pojedinačno, na dijelove sustava, te parcijalnu primjenu metoda i tehnika optimizacije (npr. lansiranje radnih naloga, iskorištavanje kapaciteta i drugih resursa i dr.)

c. u istraživanjima operativnog planiranja i praćenja tretira se dominantno proizvodanja kao sustav na koji se planiranje i praćenje odnosi, bez tretiranja procesa planiranja i praćenja u smislu njegove uspješnosti

d. manje su istražene veze koje se inače svakodnevno odvijaju između proizvodnje i logističkih funkcija – prodaje, nabave, prijevoza, održavanja i dr., a koje treba povezivati, usklađivati o optimizirati putem operativnog planiranja i praćenja, kako po pitanju sadržaja-informacija tako i po pitanju aktivnosti-operacija

e. nema dovoljno istraživanja u kojima se preciznije utvrđuju utjecajni faktori na proces operativnoh planiranja i praćenja, niti odgovarajući kriteriji i mjerila

f. premalo je istraživanja koja se odnose na izučavanje operativnog planiranja i praćenja u uvjetima većeg broja i intenziteta promjena i poremećaja

g. mali broj istraživanja u kojima se optimizira prilagodljivost i fleksibilnost sustava kao pokazatelje njegove dinamičke optimizacije rada i poslovanja, pri čemu se kao kriteriji uzimaju minimalni troškovi odnosno vremena realizacije

h. planira se i optimizira proizvodnja po kriterijima koji ne uzimaju u potpunosti uvjete te veličinu i brzinu promjene u okolini, a dinamičko planiranje i praćenje po odgovarajućim metodama i tehnikama rada prisutno je parcijalno, obuhvaćajući pri tome samo određene sadržaje tretiranog procesa, najčešće samo proizvodnje

i. nema dovoljno istraživanja u kojima bi se proučavala interakcijska djelovanja između planiranja i praćenja i proizvodnje, prodaje, nabave i drugih pratećih procesa

Matematičke metode optimizacije razvijene su u doba iza II. svjetskog rata kada je bilo bitno proizvesti dobra jer ih je tržište bilo gladno pa je naglasak bio na optimizaciji po kriteriju maksimuma prihoda, zauzetosti kapaciteta i profita. Danas su uvjeti u okruženju značajno promijenjeni, dominiraju oštri zakoni tržišta uz značajne promjene i poremećaje.

Može se vidjeti da je sve više znanstvenih radova koji se bave istraživanjem planiranja i praćenja za specifične uvjete proizvodnje i poslovanja kao što je proizvodnja po narudžbi, pojedinačna proizvodnja, proizvodnja u nestabilnim uvjetima.

No, ne postoji istraživanje koje bi se neposrednije i detaljnije pozabavilo optimizacijom samog procesa planiranja i praćenja, kako u smislu uspješnosti upravljanja proizvodnjom putem praćenja odstupanja realizacije u odnosu na postavljene planove. Uz to svakako treba ukuljučiti i optimiranje troškova procesa planiranja i praćenja u odnosu na postavljene ciljeve i kriterije proizvodnje i poslovanja te promjene u tretiranom poslovnom sustavu i okruženju.

2.4. Ocjena planiranja i praćenja u praksi

Promatrajući i analizirajući praktična saznanja u neposrednom radu na 8 projekata razvoja i primjene planiranja i praćenja u domaćim proizvodnim poduzećima, uočeni su problemi i posljedice planiranja i praćenja proizvodnje i ostalih usko vezanih procesa, kako slijedi:

1. Proces planiranja i praćenja proizvodnje nije cjelovit na nivou organizacijskog procesa, niti se kontinuirano i neposredno izvodi. Između operativnog i dugoročnog planiranja i praćenja ne postoji dovoljno velika povezanost, kontinuitet i usklađenost već su to obično dva odvojena procesa. Sličan je problem između planiranja i praćenja rada i sadržaja neke cjeline u odnosu na pojedinca u tom procesu. Proces planiranja i praćenja najintenzivnije je vezan za proces proizvodnje s nešto slabijim vezama u povratnom smislu a najslabije je vezan s procesom razvoja. Taj nejednoliki tretman i utjecaj planiranja i praćenja u odnosu na ostale organizacijske procese umanjuje uspješnost ukupnog organizacijskog procesa. Čest je parcijalan pristup, a posljedice su suboptimalna rješenja te nepotpuno i nedovoljno efikasno korištenje raspoloživih potencijala.

2. Planiranje i praćenje proizvodnje tretira se i izvodi više statički nego dinamički, a tretiranje faktora vremena nije u potrebnoj mjeri primjereno potrebama i promjenama u okruženju. U tom smislu nije ni potpuno niti dovoljno usklađena veza između planiranja i praćenja za kraće vremenske periode u odnosu na duže periode, i obrnuto. Zbog toga se ne obuhvaćaju svi parametri obrađivanog procesa i njegovih sadržaja u dovoljnoj mjeri pa nema punog kontinuiteta i veličine efekata u radu i rezultatima. Dinamičko planiranje i praćenje po odgovarajućim metodama i tehnikama rada prisutno je parcijalno, obuhvaćajući pri tome samo određene sadržaje tretiranog procesa, najčešće samo proizvodnje. Ono zadovoljava samo u onim slučajevima gdje postoje jasno izražene i dovoljno stabilne i pravilne zakonitosti, no njih je danas jako malo pa je širina primjene i obuhvata takvog dinamičkog planiranja i praćenja ograničena, a efekti nedovoljno značajni.

3. Danas je planiranje i praćenje proizvodnje više skup metoda i tehnika rada nego jasno i precizno definiran i logički povezan proces, s odgovarajućim algoritmima i primjereno ukomponiranim metodama i tehnikama rada. Sadašnja saznanja u teoriji planiranja i praćenja, odnosno upravljanja, i spoznaje u primjeni najvećim se dijelom odnose na tehnologiju, kontrolu, teoriju zaliha, teoriju odlučivanja, metode i tehnike optimizacije.

Također je obuhvaćen marketing snabdjevanja i plasmana tj. tržišta, uključujući tu manjim dijelom definirane procese i odnose, a većim dijelom parcijalno i nezavisno primijenjene i obrađene metode rada. Rezultat takvog pristupa i tretmana planiranja i praćenja proizvodnje je često nametanje matematičkih metoda i tehnika rada u odnosu na tok i sadržaj planiranja i praćenja. Time se gubi prirodnost i logika problema, problem se odvaja od stvarnosti pa su posljedice suboptimalni rezultati i osjetno smanjeni efekti.

Radi se o evidentno obrnutom pristupu tretiranja problema i njegovog rješavanja gdje se problem prilagođava razvijenoj metodi i tehnici rada umjesto da se izabere ili razvije odgovarajuća metoda i tehnika rada primjerena karakteru i obuhvatu problema. Taj se problem posebno potencira postavljanjem prirodnog problema procesa planiranja i praćenja u podređeni položaj prema vlastitom informatičkom podprocesu i sposobnostima raspoloživog računala kao pomagala u radu. Zbog toga se često gubi smisao problema i potrebe, a posljedice su veliki troškovi u odnosu na dobivene rezultate.

4. Informatički potproces planiranja i praćenja (prijem, obrada, slanje podataka i dokumenata) ne smatra se u potpunosti kao njegov sastavni dio već se tretira kao paralelan, često nezavisan proces, prije svega zbog dominacije metoda i tehnika rada te korištenih pomagala u radu, posebno računala. Vrlo često se aktivnosti i algoritmi procesa planiranja i praćenja definiraju i projektiraju prema prethodno utvrđenim informacijskim tokovima i načinu funkcioniranja pomagala u radu. U takvom slučaju aktivnosti planiranja i praćenja se odvijaju u neskladu s definiranim informacijskim podprocesom, bez dovoljne i ažurne usklade. Kao rezultat takvog stanja pojavljuje se dvojnost u planiranju i praćenju pa nema očekivane efikasnosti, a pojavljuju se nepotrebni troškovi. Primjena računala određuje se prema projektiranom ili primijenjenom informacijskom potprocesu, a često i obrnuto, necjelovito i nedovoljno povezano u odnosu na potreban prirodni i logični tok i sadržaj procesa planiranja i praćenja.

5. Čovjek se u procesu planiranja i praćenja češće tretira kao resurs i kao njegov objekt, a manje kao subjekt tog procesa. I samo obrazovanje čovjeka za sudjelovanje u tom procesu nije primjereno potrebama pa je čovjek više izvršilac nego kreator procesa i njegovih sadržaja, jer je osposobljen za primjenu metoda i tehnika rada. Na taj način imamo paradoks nesklada znanja jer poznamo proces daleko manje nego metode i tehnike rada za primjenu u tom procesu.

Zbog svega toga je čovjek s jedne strane manje iskorišten nego što su njegovi potencijali, a s druge strane je zbog takve uloge čest uzročnik poremećaja u procesu, i to ne samo u procesu planiranja i praćenja. Zato su efekti u radu osjetno manji od mogućih, a najveće štete u slučaju poremećaja planiranja i praćenja izazvane su zbog faktora čovjeka. Istovremeno, na taj način rada nema intenzivnog razvoja i unapređenja kako samog procesa tako ni čovjeka, a što utječe na njegovo nezadovoljstvo u radu i što u konačnosti uzrokuje smanjenje efekata.

6. Veza s okruženjem nekog sistema čiji se proces planiranja i praćenja promatra najčešće su intenzivne, a posebno se mnogo radi na istraživanju tržišta. No, veza obično nije jednako kvalitetna u oba smjera pošto se kriteriji optimizacije postavljaju prioritetno za samu sredinu – privredni ili negi drugi sistem. Čak i kada se ostvaruju maksimalni efekti i minimalni troškovi u takvom radu, oni su parcijalni, samo za promatranu sredinu, pri čemu se u njoj ne osigurava veće i objektivno zadovoljstvo sudionika u procesu. Potrebe okruženja zadovoljavaju se djelomično, interesno samo sa aspekta dijela kriterija zadovoljstva, što s vremenom dovodi do poremećaja i kriza.

7. Promatrajući i analizirajući probleme planiranja i praćenja na višim i složenijim nivoima života i rada, u privredi, a posebno van nje, uočavamo veći intenzitet gore navedenih problema. To znači da se nedostaci i posljedice manifestiraju u većoj mjeri pa možemo generalno reći da je planiranje i praćenje manje prisutno i efikasno što je veći sustav kod kojeg se taj proces promatra. Taj je zaključak s jedne strane i logičan zbog veličine i složenosti takvih sustava, no samo djelomično jer bi zapravo to trebao biti razlog intenzivnijeg bavljenja planiranjem i praćenjem u većim i složenijim sustavima. Naime, nemoguće je kvalitetno voditi i razvijati planiranje i praćenje nižih i manje složenih sustava ako se to barem jednako ili čak kvalitetnije ne radi i na višim nivoima. Stoga možemo ponovo ustvrditi da se radi o parcijalnom rješavanju problema što neizostavno dovodi do veće ili manje suboptimalizacije rješenja. Posljedice takvog stanja manifestiraju se u gomilanju ekoloških problema, neravnomjernom i neprimjerenom razvoju, a samim time dolazi do sukoba u različitim oblicima, pa i oružanim.

2.5. Ciljevi, hipoteza i očekivani doprinos istraživanja

Uočavajući problem planiranja i praćenja proizvodnje vidjelo se da je on sastavni dio problema organizacije i da je u operativnom smislu vezan za sve organizacijske procese nekog sustava, konkretno proizvodnog poduzeća. Posebno je vezan na operativne dijelove kao što su proizvodnja, plasman i snabdijevanje pa ga zato treba promatrati u tim okvirima, nedjeljivo i sa svim popratnim vezama između tih dijelova proizvodnog sustava, ali i šire.

U tom kontekstu postoji problem planiranja i praćenja proizvodnje s aspekta postupka njegovog izvođenja i obuhvata, a gdje je prisutna nedovoljna povezanost, kako njegovih dijelova tako i veza s drugim procesima te je usko područje njegove prisutnosti u svim ostalim dijelovima organizacijskog procesa proizvodnog sustava, posebno s onim izvan njega.

Planiranje i praćenje proizvodnje ne sastoji se samo od optimiranja planova već se u tom procesu zbiva niz aktivnosti koje dovode do optimalnih planova. No, imamo i niz aktivnosti kojima se utječe na realizaciju u proizvodnim i poslovnim procesima, kao i uklanjanje poremećaja te prilagođavanje promjenama koje se događaju u konkretnom sustavu i njegovom okruženju.

Namjera je ovog istraživanja da se neposrednije i detaljnije pozabavi optimizacijom samog procesa planiranja i praćenja proizvodnje, kako u smislu uspješnosti upravljanja proizvodnjom putem praćenja odstupanja realizacije u odnosu na postavljene planove tako i u smislu optimiranja troškova procesa planiranja i praćenja u odnosu na postavljene ciljeve i kriterije proizvodnje i poslovanja te promjena u tretiranom poslovnom sustavu i okruženju.

U ovom istraživanju žele se postići sljedeći **ciljevi**:

A. Utvrditi utjecajne faktora na proces i rezultate planiranja i praćenja proizvodnje te odrediti postupak njegovog modeliranja i optimizacije u različitim sustavima i uvjetima prema funkciji utjecajnih varijabli pripadajućeg sustava.
Obzirom da je svako poduzeće po sebi i svojem okruženju specifično, vrlo je važno znati kako odrediti faktore koji utječu na njegov proces planiranja i praćenja i što će biti odrednice za njegovo oblikovanje i optimizaciju.

B. Odrediti objektivne kriterije i mjerila za ocjenjivanje uspješnosti planiranja i praćenja proizvodnje te mogućnost usporedbe uspješnosti tog procesa u raznim razdobljima i vrstama proizvodnih sustava, bez obzira na veličinu i djelatnost.

Kako za optimizaciju planova proizvodnje i poslovanja postoje brojni kriteriji i mjerila isto tako su potrebni i objektivni kriteriji i mjerila za ocjenjivanje uspješnosti planiranja i praćenja kao procesa kako bi se mogla vrednovati prilagodljivost proizvodnog sustava potrebama i promjenama u njegovom okruženju i njemu samom.

C. Izraditi model fleksibilnog i prilagodljivog procesa planiranja i praćenja proizvodnje i optimizacije korekcije planova sukladno promjenama.

Svako istraživanje bi pored ostalog trebalo dati barem pravce rješenja pa se kao glavni cilj ovog istraživanja namjerava izraditi model fleksibilnog i prilagodljivog procesa planiranja i praćenja proizvodnje s prijedlogom mogućeg rješenja za optimizaciju potrebne korekcije planova u skladu s promjenama u okruženju i samom sustavu.

Pri tome se postavlja **hipoteza** ovog istraživanja da izbor modela i optimizacija procesa planiranja i praćenja proizvodnje značajno utječe na uspješnost i prilagodljivost proizvodnog sustava i poslovanja u uvjetima dinamičnih promjena u okruženju i samom proizvodnom sustavu, a što traži kontinuiranu korekciju optimuma u planovima proizvodnje. Drugim riječima, to znači da se modeliranjem i optimizacijom procesa planiranja i praćenja u smislu njegove prilagodljivosti može postići veći stupanj njegove uspješnosti i zadovoljenja potreba okruženja nego je to slučaj kod poznatih metoda i tehnika optimizacije planova.

Na proces i rezultate planiranja i praćenja proizvodnje djeluje velik broj utjecajnih faktora koji proizlaze iz strukture i procesa proizvodnog sustava, njegovog predmeta i tehnologije rada i parametara iz okruženja pri čemu se može očekivati da će isti utjecajni faktori različito djelovati u različitim proizvodnim sustavima i njihovim okruženjima. Zbog toga će biti vrlo značajno kako odrediti utjecajne faktore te kako pristupiti projektiranju procesa planiranja i praćenja u različitim sustavima i uvjetima.

No, da bi vidjeli jačinu djelovanja pojedinih utjecajnih faktora na uspješnost planiranja i praćenja, potrebno je odabrati odgovarajuće kriterije i mjerila. Pri tome bi bilo poželjno da se koriste oni kriteriji i mjerila koja će omogućiti uspoređivanje uspješnosti tog procesa u različitim razdobljima i između različitih proizvodnih sustava, bez obzira na veličinu i djelatnost.

Treći cilj bi trebala biti izrada prijedloga općeg modela fleksibilnog i prilagodljivog procesa planiranja i praćenja s algoritmima za optimizaciju planova proizvodnje u smislu kontinuirane korekcije polaznih optimalnih planova proizvodnje, a prema kriteriju uspješnosti proizvodnje i poslovanja te promjenama u tretiranom poslovnom sustavu i okruženju.

Naime, čak i u slučaju maksimalnog poslovnog rezultata dobivenog optimizacijom planova proizvodnje i poslovanja po kriteriju profita (ili minimalnih troškova proizvodnje, maksimalnog iskorištenja kapaciteta, maksimalnog zadovoljenja potreba tržišta-zahtjeva kupaca i drugih kriterija) ostaje otvoreno pitanje izvršenja takvog plana i stvarne cijene takvog planiranog rezultata za neko plansko razdoblje.

Tu se misli na troškove planiranja, prikupljanja ulaznih informacija, pouzdanosti procesa vezanih za planiranje, praćenje i realizaciju proizvodnje (prodaja, nabava, proizvodnja, održavanje, transport i dr.) a posebno troškove zaliha materijala i gotovih proizvoda te troškova koje proizvodni sustav može imati direktno ili indirektno u slučaju odstupanja od ugovorenih, planiranih rokova isporuke.

Proces planiranja i praćenja je taj proces koji ima zadatak ostvariti maksimalni rezultat uz minimalne troškove, ne samo putem iznalaženja i izrade najpovoljnijih planova nego u tijekom upravljanja realizacijom proizvodnje. Zbog toga je bitno odrediti optimalni proces planiranja i praćenja za neki proizvodni-poslovni sustav temeljem postavljenih kriterija i mjerila.

Procjenjuje se da će se **očekivani znanstveni doprinos** iskazati u sljedećem:

1. Postupak istraživanja, određivanja i vrednovanja utjecajnih faktora te veza s drugim organizacijskim procesima sustava kao osnove za izbor modela i optimizacije u okviru rješenja procesa planiranja i praćenja proizvodnje u uvjetima promjena;
2. Novi, sintetizirani kriteriji i mjerila za izradu modela fleksibilnog i prilagodljivog procesa i sadržaja planiranja i praćenja proizvodnje različitih proizvodnih sustava u uvjetima promjena i poremećaja u okolini promatranog poslovnog sustava, s pokazateljima uspješnosti;
3. Model korektivne optimizacije polaznih operativnih planova proizvodnje sa sintetskim kriterijima i odgovarajućim algoritmima u uvjetima promjena i poremećaja, kao dio modela prilagodljivog planiranja i praćenja proizvodnje;
4. Metode vrednovanja i uspoređivanja uspješnosti procesa planiranja i praćenja proizvodnje različitih proizvodnih sustava te mogući pravci i potrebe daljnjeg istraživanja modeliranja i optimizacije procesa planiranja i praćenja proizvodnje.

3. POSTAVLJANJE ZADATKA ZA ISTRAŽIVANJE

3.1. Opis problema za istraživanje

Da bi se što kvalitetnije i preciznije istražio opisani problem planiranja i praćenja proizvodnje te postigli postavljeni ciljevi i ostvario očekivani znanstveni doprinos, kao prostorne granice ovog istraživanja uzeti će se proizvodni sustav s glavnim dijelovima njegovog organizacijskog procesa, kako je prikazano na slici 5., a što uključuje procese:

a. planiranje i praćenje

b. proizvodnja- realizacija

c. snabdijevanje-nabava

d. plasman-prodaja

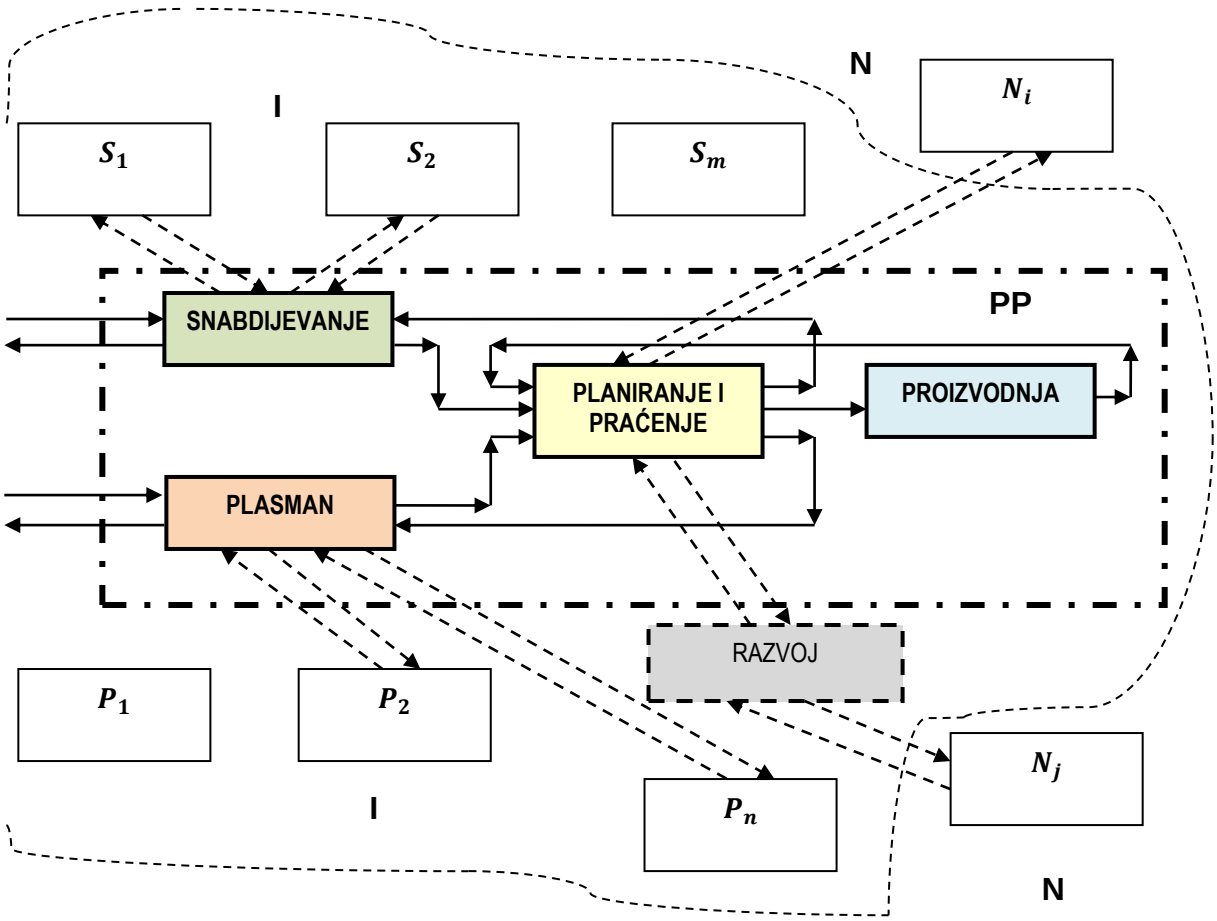

PP – objekt istraživanja **I** - privredno okruženje **N** - životno okruženje
S_i, P_j- sustavi povezani s objektom N_{ij} - sustavi nadogradnje povezani s objektom

Slika 5. *Shematski prikaz prostornih granica u istraživanju*

Granice znanja koje obuhvaćaju područje znanosti i spoznaja prisutnih u istraživanju ovdje će obuhvatiti prvenstveno znanja vezana za područje organizacije. Tu su uz znanja o organizaciji u užem smislu prisutna i uključena informatička, ekonomska, tehnička, matematičko-statistička i znanja o čovjeku, prvenstveno sociološko-psihološka, te svakako treba dodati i opća znanja o razvoju i tehnologiji.

Obzirom na prostorne granice te potrebu da se primjenom znanja stvaraju nova znanja i sam karakter problema, ovo će istraživanje po svojim obilježjima biti dijelom teorijsko, a dijelom primijenjeno istraživanje pa će to s jedne strane i determinirati granice znanja ukupno, kao i po znanstvenim područjima koja će se koristiti u istraživanju.

Planiranje i praćenje procesa, kako radnih (proizvodnja, poslovanje) tako i životnih, ima po hijerarhiji i složenosti 3 nivoa funkcija koje se mogu definirati kao:

1. IZVRŠENJE – I. nivo, kao najniži nivo gdje se planiranje i praćenje prožima i povezuje sa izvršnim podprocesima
2. PRIPREMA – II. nivo, kao srednji nivo gdje se priprema realizacija poslova--aktivnosti te povezivanje s ostalim relevantnim procesima
3. UPRAVLJANJE – II. nivo, najviši, kao dio upravljačkog procesa cjelog sustava

Najviše egzaktnih znanstvenih spoznaja i rješenja iz područja planiranja i praćenja proizvodnje vezano je za prva dva nivou funkcija tog procesa, s velikim brojem modela i tehnika optimizacije, dok za treći, najviši nivo ima manje poznatih spoznaja i rješenja.

Uzrok tome je najvjerojatnije vezan za utjecaje faktora čovjeka u organizacijskim i upravljačkim procesima, a posebno iz razloga sve većeg broja i intenziteta promjena u okolini koji utječu na organizacijski sustav pa samim time i na planiranje i praćenje. To bi po svoj prilici bilo ishodište problema koje bi trebalo intenzivnije znanstveno izučavati, kako je to već navedeno u nekim znanstvenim radovima [31, 37].

Obzirom da se planiranje i praćenje proizvodnje izvode povezano i kontinuirano, taj proces se može zvati upravljanje organizacijskim procesom određenog sustava, kako se najčešće i naziva u znanosti i praksi, pa ga je potrebno i ocjenjivati u smislu uspješnosti i efikasnosti. U fazi realizacije proizvodnje obavlja se njeno praćenje ne samo zbog utvrđivanja da li se planiranje izvodi kako je definirano i kakvi su rezultati i pokazatelji uspješnosti, već i zbog toga da se na vrijeme utvrde eventualno nastali poremećaji, a koji se u nastavku planiranja usklađuju sa postojećim stanjem i ciljevima, i obrnuto.

Taj dio planiranja i praćenja relativno je slabije istražen, a u praksi se pokazuje kao njegov najveći i najsloženiji dio te zaslužuje pomnije i intenzivnije istraživanje, a posebno je značajno utvrditi njegovu efikasnost, odnosno uspješnost.

Danas se kod operativnog planiranja i praćenja proizvodnje pojavljuju dva glavna problema:

a. PROBLEM OPTIMALNOSTI PLANOVA PROIZVODNJE
Optimalnost se dominantno tretira s aspekta same proizvodnje i u manjoj ili većoj mjeri odstupa od aktualnih zbivanja i promjena na tržištu u tretiranom razdoblju.

b. PROBLEM USPJEŠNOSTI PROCESA PLANIRANJA I PRAĆENJA
Ne postoji precizniji uvid u utjecaj neposrednog procesa operativnog planiranja i praćenja na samu proizvodnju, i obrnuto.

Kod problema određivanja optimalnih planova prvi dio problema je izbor kriterija optimizacije – da li je za proizvodni sustav najpovoljniji kriterij maksimalno iskorištenje kapaciteta, ostvarenje maksimalnog profita, postizanje minimalnih troškova proizvodnje ili nešto drugo. Uz to, postoji i drugi dio problema a to je optimalnost u uvjetima promjena i poremećaja, kako u okruženju tako i u samom sustavu.

Korištenjem poznatih metoda i tehnike optimizacije planova proizvodnje uvijek se u određenoj mjeri stvarnost u proizvodnji i njenom okruženju prilagođava matematičkom modelu pa u promatranom razdoblju dolazi do nesklada s potrebama okoline. Tako se u realizaciji proizvodnje dio proizvodnog programa proizvodi više, a dio manje od potreba okoline što u konačnosti izaziva negativne efekte za sustav. Ako nekog proizvoda nema dovoljno za tržište, reakcija potencijalnih kupaca je negativna, a ako ima viška nekih proizvoda koji se kasnije ne mogu regularno prodati, to negativno utječe na poslovni rezultat proizvodnog sustava.

Drugi dio problema optimalnosti planova je problem mogućnosti i načina optimizacije potrebnih korekcija aktualnih optimalnih planova proizvodnje kada se događaju veće i brze promjene u okolini ili kada sustav ima poremećaje ili zastoje s naslova kapaciteta, dobave repromaterijala ili rada ljudi. To znači da postoji problem fleksibilnosti i prilagodljivosti proizvodnog sustava u uvjetima promjena, odnosno optimizacije proizvodnje u takvim uvjetima te pitanje kako ga postići.

Drugi problem se odnosi na planiranje i praćenje proizvodnje kao procesa koji treba dati svoj doprinos da proizvodnja zaista postigne planirani optimum i gdje se postavlja pitanje koliki je i kakav je doprinos procesa planiranja i praćenja u postizanju efikasnosti i uspješnosti proizvodnje te uz koje se kriterije i mjerila to može ocjenjivati..

Kako su rezultati proizvodnog procesa najvećim dijelom posljedica načina i efikasnosti vođenja i realizacije procesa operativnog planiranja i praćenja, dobiveni rezultati i ocjene efikasnosti proizvodnje trebaju biti i ocjene uspješnosti operativnog planiranja i praćenja.

U brojnoj literaturi, [1, 2, 3, 4, 5, 6, 7], posebno onoj iz područja ekonomike proizvodnje, kao i svakodnevnoj praksi, poslovni uspjeh proizvodnje mjeri se sa sljedećim standardnim pokazateljima:

- **ekonomičnost** = odnos ostvarenog i utrošenog novca
- **proizvodnost** = odnos količine učinka i uloženog rada
- **rentabilnost** = odnos ostvarenog profita i uloženog kapitala

Navedeni pokazatelji sintetski ocjenjuju poslovni uspjeh proizvodnje, ali nam ne govore u kojoj mjeri na njih utječu djelujući utjecajni faktori operativnog planiranja i praćenja te same proizvodnje.

Drugi problem se javlja u praksi, gotovo kod svih proizvodnih sustava, kada zbog manje ili više dinamičnih promjena na tržištu dolazi do potrebe promjena, dopuna i izmjena operativnih planova proizvodnje [9, 13, 16, 20, 28, 34]. S aspekta tržišta, preferira se što veće zadovoljenje potreba tržišta, dok sustav proizvodnje nastoji realizirati onakve planove koji omogućuju optimalne rezultate prema prethodno odabranim kriterijima i mjerilima.

Možemo praktično zaključiti da se ne samo zbog određenog broja poremećaja u procesu realizacije proizvodnje već i zbog potrebe što većeg i kvalitetnijeg zadovoljavanja potreba tržišta ne mogu u većini slučajeva očekivati optimalni planirani rezultati već se njima može samo težiti. Takvim planiranim rezultatima bliže se dolazi ako se proizvodnim sustavom bolje upravlja kvalitetnijim procesom operativnog planiranja i praćenja i ako se sa tržišta dobivaju ulazni podaci koji su precizniji i dolaze na vrijeme [31, 37].

S druge strane, važno je napomenuti da se u svakom istraživanju istina po nekom pitanju – cilju treba uvijek tražiti u okviru cjeline predmetnog problema, bez obzira na koji će se važan znanstveni dio istraživanje usmjeriti i usredotočiti. Tako će i u ovom istraživanju biti važno sagledati glavne dijelove i obilježja cjeline planiranja i praćenja proizvodnje kako bi se detaljnije istražio i znanstveno spoznao onaj dio problema koji se ocijeni važnim i značajnim.

Obzirom na do sada uočene probleme planiranja i praćenja proizvodnje, nastojati će se sagledati veći broj utjecaja i uzroka tog problema, u okviru okruženja procesa planiranja i praćenja i njegovih veza s drugim procesima proizvodnih poduzeća, po mogućnosti za one proizvodne sustave koji su najzastupljeniji.

Stoga se kao glavni problem ovog istraživanja nameće problem modeliranja i optimiranja fleksibilnog i prilagodljivog procesa planiranja i praćenja proizvodnje. Zadnjih nekoliko godina velik je broj znanstvenih radova koji se bave dijelovima tog problema u specifičnim uvjetima proizvodnog sustava gdje se naglasak stavlja na istraživanje metoda i tehnika optimiranja u uvjetima nestabilnosti i promjena.

No, poželjno bi bilo iznaći i rješenja za takve modele procesa planiranja i praćenja proizvodnje koji bi omogućili veću prilagodljivost proizvodnog sustava u uvjetima promjena i nestabilnosti, odnosno što veću uspješnost procesa planiranja i praćenja proizvodnje. Pri tome bi bilo poželjno da model prilagodljivog planiranja i praćenja bude primjenjiv za što veći broj tipova i karakteristika proizvodnje.

Zato će se u ovom istraživanju naglasak staviti na iznalaženje modela prilagodljivog planiranja i praćenja proizvodnje koji će biti primjenjiv za tipove i oblike proizvodnje koji su najzastupljeniji i najtipičniji a to je serijska proizvodnja za kombiniranu isporuku putem narudžbi serija i isporuka sa zaliha gotovih proizvoda u skladištu. No, to ne bi trebalo isključiti i eventualnu, barem djelomičnu primjenu i za ostale tipove proizvodnje.

Za daljnje istraživanje i ocjenjivanje dobivenih rezultata potrebno je unaprijed odrediti kriterije i mjerila. Moguće je koristiti više kriterija i mjerila, no poželjno je odrediti ona koja se algoritamski mogu povezati u jedinstveni sintetski kriterij, a koji će dati što objektivniju sliku o ocijenu istraživanja i rezultata. To znači potrebu postavljanja objektivnih kriterija za ocjenjivanje uspješnosti procesa planiranja i praćenja proizvodnje.

3.2. Kriteriji i mjerila

U teoriji i praksi proizvodnje i njenog upravljanja postoji velik broj kriterija i mjerila za optimizaciju programa i planova proizvodnje, a neki od njih su ujedno i pokazatelji koji govore o efikasnosti i uspješnosti neke proizvodnje, odnosno imamo kriterije i mjerila kojima se pojedinačno daje uvid u rezultate nekog proizvodnog procesa ili njegovih dijelova i sadržaja.

Kako se putem operativnog planiranja i praćenja najviše utječe na efikasnost i uspješnost neposrednog procesa proizvodnje, bilo bi potrebno razmotriti kriterije i mjerila po kojima bi se ocjenjivala uspješnost i efikasnost tog organizacijskog procesa, a ne samo proizvodnje i njenih dijelova.

Pretraživanjem većeg broja znanstvene i stručne literature i članaka te prikupljenih iskustava u praksi vezanoj za područje operativnog planiranja i praćenja proizvodnje, može se utvrditi da se odabrani kriteriji i mjerila koriste uglavnom za optimizaciju proizvodnje, gdje se najčešće susreću sljedeći kriteriji i mjerila:

a. profit (novac) [1, 2]
b. troškovi proizvodnje (novac) [4, 5, 7, 8]
c. količina proizvoda (broj/volumen/težina) [5]
d. utrošeno vrijeme (sati, dani) [3, 4, 9]
e. utrošeno dodatno vrijeme (sati, dani) [3]
f. utrošeni materijali (količina) [4]
g. troškovi radnika (novac) [8]
h. iskorišteni kapaciteti (vrijeme, %) [6, 8, 9]
i. utrošeni dodatni kapaciteti (vrijeme, %) [7]

Po istim kriterijima i mjerilima daje se i ocjena uspješnosti proizvodnje prema odnosu planiranih i dobivenih rezultata proizvodnje. Kako se može zaključiti iz navedenog, radi se o većem broju kriterija i mjerila koji daju pojedinačne ocjene uspješnosti proizvodnog procesa od kojih je samo kriterij "profit" sintetski, ali iz njega ne možemo dobiti sliku djelovanja utjecajnih faktora proizvodnje i operativnog planiranja i praćenja na njihovu uspješnost. Osim toga, navedeni kriteriji i mjerila ne daju dovoljan uvid u kvalitetu i efikasnost odvijanja procesa operativnog planiranja i praćenja te same proizvodnje.

Drugi problem se javlja u praksi, gotovo kod svih proizvodnih sustava, kada zbog manje ili više dinamičnih promjena na tržištu dolazi do potrebe promjena, dopuna i izmjena operativnih planova proizvodnje. S aspekta tržišta, preferira se što veće zadovoljenje potreba tržišta dok sustav proizvodnje nastoji realizirati onakve planove koji omogućuju optimalne rezultate prema prethodno odabranim kriterijima i mjerilima. Možemo zaključiti da se ne samo zbog određenog broja poremećaja u procesu realizacije proizvodnje već i zbog potrebe što većeg i kvalitetnijeg zadovoljavanja potreba tržišta u većini slučajeva ne mogu očekivati optimalni planirani rezultati, već se njima može samo težiti.

Takvim planiranim rezultatima bliže se dolazi ako se proizvodnim sustavom bolje upravlja kvalitetnijim procesom operativnog planiranja i praćenja i ako se sa tržišta dobivaju ulazni podaci koji su precizniji i dolaze na vrijeme. Operativno planiranje i praćenje proizvodnje je proces koji povezuje proizvodnju i tržište pa je samim time jasno koliko je to važan proces te ga treba ne samo dobro organizirati i voditi, već i na odgovarajući način pratiti i ocjenjivati.

Prema složenosti problema može se pojaviti potreba za primjenu više kriterija i njima odgovarajućih mjerila i u tom je slučaju teško dati jedinstvenu i sveobuhvatnu ocjenu stanja, utjecajnih faktora ili rješenja, odnosno odabrati zaista optimalno rješenje. Zato je potrebno stvoriti manji broj sintetskih kriterija i mjerila, po mogućnosti samo jedno, a poželjno je da mjerilo bude bezdimenzionalno kako bi se mogle obavljati usporedbe predmetnog rješenja ili istraživanja s drugima.

Pošto se ovdje želi ocjenjivati operativno planiranje i praćenje procesa, prije svega proizvodnje, a njega oslikava i definira trinom KVALITETA-ROKOVI-TROŠKOVI, uspješnost planiranja i praćenja proizvodnje trebalo bi određivati po kriterijima i mjerilima koji će govoriti o svakom dijelu navedenog trinoma.

Stoga se ovdje predlažu tri kriterija za ocjenjivanje uspješnosti operativnog planiranja i praćenja proizvodnje, a koji su odabrani tako da mogu biti primijenjeni u što većem broju područja života i rada i da se mogu povezati u jedinstveni, sintetski kriterij za ocjenjivanje uspješnosti, i to:

1. Stupanj realizacije na tržištu u odnosu na operativne planove i realizaciju proizvodnje – OSJETLJIVOST PLANIRANJA I PRAĆENJA - $\boldsymbol{U_1}$
2. Stupanj zadovoljavanja rokova isporuke – ZADOVOLJENOST ROKOVA – $\boldsymbol{U_2}$
3. Stupanj učešće svih zaliha u odnosu na realizaciju na tržištu i potrošnju u proizvodnji – EFIKASNOST UPRAVLJANJA ZALIHAMA – $\boldsymbol{U_3}$

Za sve navedene kriterije mjerila su bezdimenzionalna i izražena su u postocima (%) čime se osigurava da se na taj način mogu uspoređivati rezultati nekog sustava iz različitih vremenskih razdoblja kao i različiti proizvodni procesi, odnosno organizacijski sustavi, bez obzira na njihovu veličinu i sadržaj rada.

Za ukupnu, sintetsku ocjenu uspješnosti operativnog planiranja i praćenja odabire se pojam USPJEŠNOST PLANIRANJA – $\boldsymbol{U}$ koji predstavlja skup odabranih pojedinačnih kriterija po odgovarajućem algoritmu.

3.2.1. Kriterij $\boldsymbol{U_1}$ – *osjetljivost planiranja i praćenja*

Ovaj kriterij za ocjenjivanje osjetljivosti operativnog planiranja i praćenja proizvodnje obuhvaća stupanj mjesečne realizacije proizvoda na tržištu u odnosu na:

- godišnji plan (njegovu dvanaestinu, 1/12)
- mjesečni plan realizacije plasmana
- realiziranu mjesečnu proizvodnju

Na taj način obuhvaćamo ocjenjivanje operativnog planiranja i praćenja proizvodnje od njegovog početka pa do kraja i istovremeno stječemo uvid u prilagodbe na promjene koje su se u tom smislu vremenski odvijale u promatranom procesu. Po tom se kriteriju može utvrditi osjetljivost planiranja i praćenja za sadašnje stanje, djelovanje utjecajnih faktora na osjetljivost planiranja i praćenja te nivo osjetljivosti planiranja i praćenja po odabranom rješenju – programu proizvodnje u promatranom razdoblju.

Kriterij $\boldsymbol{U_1}$ - ***osjetljivost planiranja i praćenja*** je značajan zbog toga što pokazuje kvalitetu izvođenja tog procesa, njegov utjecaj i povezanost s drugim procesima i pri tome obuhvaća sve sadržaje vezane za taj proces te uvjetuje brojne aktivnosti a time i troškove rada.

Mjerilo postignutog stupnja osjetljivosti planiranja i praćenja $\boldsymbol{U_1}$ biti će prema izrazu (1) produkt *odstupanja varijacije* (1 - $\sigma_{\bar{x}}/\bar{x}$) i *stupnja točnosti* (1 - $\Delta\bar{x}$)

$$U_1 = \left(1 - \frac{\sigma_{\bar{x}}}{\bar{x}}\right) \cdot (1 - \Delta\bar{x}) \qquad (1)$$

gdje je:

$\bar{x}$ - srednja vrijednost omjera godišnjeg i mjesečnog plana te realizacije proizvodnje u odnosu na realizaciju proizvoda na tržištu

$\sigma_{\bar{x}}$ - standardna devijacija srednje vrijednosti promatranog omjera $\bar{x}$

$\Delta\bar{x}$ - greška planiranja ($\Delta\bar{x}$ = I1$-\bar{x}$ l)

y_{1ij} - 1/12 godišnjeg plana (GP) grupe proizvoda (j), (i=1,2,…12; j=1,2,…p)

y_{2ij} - mjesečni plan (MP) grupe proizvoda (j), (i=1,2,…12; j=1,2,…p)

y_{3ij} - mjesečna proizvodnja (PR) grupe proizvoda (j), (i=1,2,…12; j=1,2,…p)

y_{4ij} - mjesečna prodaja (PD) grupe proizvoda (j), (i=1,2,…12; j=1,2,…p

x_{1ij} - omjer 1/12 godišnjeg plana GP i mjesečne prodaje (x_{1ij}=y_{1ij}/y_{4ij}) grupe proizvoda (j)

x_{2ij} - omjer mjesečnog plan MP i mjesečne prodaje (x_{2ij}=y_{2ij}/y_{4ij}) grupe proizvoda

x_{3ij}- omjer mjesečne proizvodnje PR i mjesečne prodaje (x_{3ij}=y_{3ij}/y_{4ij}) grupe proizvoda (j)

x_{kij} - omjer plana i proizvodnje s mjesečnom prodajom (k=1,2,3, i=1,2,…12; j=1,2,…p)

p - broj grupa proizvoda

$$\bar{x} = \frac{\sum_{i,j} x_{1ij} + \sum_{i,j} x_{2ij} + \sum_{i,j} x_{3ij}}{3 \cdot 12 \cdot p} \tag{2}$$

Postignuti stupanj osjetljivosti planiranja i praćenja $\boldsymbol{U_1}$ produkt je odstupnja varijacije (1 - $\sigma_{\bar{x}}/\bar{x}$) i stupnja točnosti (1 - $\Delta\bar{x}$). Naime, značajno je utvrditi i rasipanje $\sigma_{\bar{x}}$ oko utvrđene aritmetičke sredine $\bar{x}$ i odstupanje aritmetičke sredine $\bar{x}$ od 100%-tne točnosti planova u odnosu na realizaciju. Pošto srednja vrijednost omjera planova i realizacije $\bar{x}$ može biti veća i manja od 100%, greška planiranja $\Delta\bar{x}$, odnosno stupanj točnosti uzima se u apsolutnom iznosu I1 – $\Delta\bar{x}$I.

Stupanj osjetljivosti planiranja i praćenja $\boldsymbol{U_1}$ može poprimiti vrijednosti u sljedećim rasponima:

$$\boldsymbol{U_{1max}} = 1 \quad (\sigma_{\bar{x}} = 0; \quad \Delta\bar{x}=0\ ) \tag{3}$$

$$\boldsymbol{U_{1min}} = 0 \quad (\sigma_{\bar{x}} = \bar{x}; \quad \Delta\bar{x}=1\ ) \tag{4}$$

Vrijednost $\boldsymbol{U_1}$ biti će veća ako je $\bar{x}$ veći a $\sigma_{\bar{x}}$ i Δx manji dok svoju maksimalnu vrijednost $\boldsymbol{U_{1max}}$= 1 poprima kada je $\sigma_{\bar{x}}$ = 0 i $\bar{x}$=1, odnosno kada je $\Delta\bar{x}$=0. Njena vrijednost pada kada se $\bar{x}$ smanjuje a $\sigma_{\bar{x}}$ i $\Delta\bar{x}$ rastu a minimalnu vrijednost $\boldsymbol{U_{1min}}$ = 0 poprima kada je $\sigma_{\bar{x}}$ = $\bar{x}$ a $\Delta\bar{x}$=1. No, $\Delta\bar{x}$=1 kada bi bilo $\bar{x}$=0 a što je praktično nemoguće, odnosno besmisleno jer je to slučaj kada nema nikakvih planova ni realizacije u proizvodnji.

Može se reći da je $\boldsymbol{U_{1min}}$= 0 za sustave koji nisu u funkciji, te zaključiti da stupanj osjetljivosti planiranja i praćenja $\boldsymbol{U_1}$ teži k $\boldsymbol{U_{1max}}$ = 1 a što je i logičan cilj svakog sustava.

Ovaj kriterij je zbog uopćenosti i bezdimenzionalnog mjerila pogodan i za usporedbu osjetljivosti planiranja i praćenja kod različitih sustava, bez obzira na vrstu i karakter sustava, njegov proizvod-uslugu, veličinu i dr., a pri tome se može uzeti u razmatranje jedan ili više omjera planova i realizacije.

Kao pokazatelj vremenskih promjena u nekom sustavu ili usporedbeni pokazatelj osjetljivosti planiranja i praćenja za neki sustav u odnosu na druge ili neki referentni sustav može nam poslužiti *koeficijent osjetljivosti planiranja i praćenja* $\boldsymbol{K_{U_1}}$, prema izrazu (5)

$$\boldsymbol{K_{U_1}} = \frac{U_{1i}}{U_{1j}} \qquad K_{U_1} \leq, \geq 1 \tag{5}$$

gdje je: U_{1i} - uspoređivani stupanj osjetljivosti planiranja i praćenja

U_{1j} - referentni stupanj osjetljivosti planiranja i praćenja

3.2.2. Kriterij $\boldsymbol{U_2}$ – *zadovoljenost rokova*

Zadovoljavanje postavljenih rokova cilj je i obveza svakog sustava u njegovom funkcioniranju i svaki sustav pri tome teži da broj zadovoljenih rokova bude što veći, a ako dođe do kašnjenja da ono bude što manje kako posljedice kašnjenja ne bi bile preskupe.

Zato možemo reći da će mjerilo postignutog stupnja zadovoljenosti rokova $\boldsymbol{U_2}$ biti prema izrazu (6) produkt *učešća zadovoljenih rokova* ($(R\text{-}R_z)/R$) i *nivoa kašnjenja* ($1 - \bar{x}_z / \bar{x}_{DI}$)

$$\boldsymbol{U_2} = \frac{R-R_z}{R} \cdot (1 - \bar{x}_z / \bar{x}_{DI}) \tag{6}$$

gdje je: R - ukupni godišnji broj postavljenih rokova (dana za isporuke)

R_z - godišnji broj nepoštivanih rokova isporuke (s kašnjenjem)

$\bar{x}_z$ - prosječni broj dana kašnjenja

$\bar{x}_{DI}$ - prosječan broj dana postavljen kao rok isporuke

pri čemu je

$$\bar{x}_z = \frac{\sum f_i \cdot \bar{x}_{zi}}{\sum f_i} \tag{7}$$

gdje je: f_i - broj isporuka s nekim danima kašnjenja

$\bar{x}_{zi}$ - dani kašnjenja

$\sum f_i$ = R - ukupan broj isporuka s kašnjenjem

Stupanj zadovoljenosti rokova $\boldsymbol{U_2}$ je produkt učešća zadovoljenih rokova i nivoa kašnjenja jer nam je značajno i da imamo što manji broj nezadovoljenih rokova i da u slučaju te pojave kašnjenja budu što kraća. Ovaj kriterij je također vrlo važan za ocjenjivanje kako procesa operativnog planiranja i praćenja tako i samog procesa proizvodnje.

Stupanj zadovoljenosti rokova $\boldsymbol{U_2}$ poprima vrijednosti u sljedećim rasponima:

$$\boldsymbol{U_{2max}} = 1 \qquad (\bar{x}_z = 0; \quad R_z = 0) \tag{8}$$

$$\boldsymbol{U_{2min}} = 0 \qquad (\bar{x}_z = \bar{x}_{DI}; \quad R_z = R) \tag{9}$$

Pri tomu će vrijednosti $\boldsymbol{U_2}$ biti veće ako su $\bar{x}_z$ i R_z manji, i obrnuto, a vrijednost $\boldsymbol{U_2}$ teži k $\boldsymbol{U_{2max}} = 1$ što je i logično za svaki sistem.

Teoretski, vrijednost $\boldsymbol{U_2}$ može biti i negativna, tj. manja od 0, u slučaju kada bi bilo da je $\bar{x}_z > \bar{x}_{DI}$, no to se praktično rijetko može dogoditi jer je za očekivati da će svaki sustav povećavati $\bar{x}_{DI}$ ako mu se češće događa da je $\bar{x}_z > \bar{x}_{DI}$ a što je za svaki sustav u njegovom okruženju nepovoljno i znači mogućnost ili stvarni raspad sustava.

I ovaj kriterij je zbog svoje bezdimenzionalnosti i uopćenosti pogodan za usporedbu zadovoljenosti rokova kod različitih sustava. Pri tome se može pretpostaviti da se kod sustava s dugim ciklusima realizacije $\bar{x}_{DI}$ mogu očekivati veće vrijednosti $\bar{x}_{zi}$, tj. postoji korelacija u pozitivnom pravcu. To ujedno znači da karakter i vrsta, proizvod, proizvodni ciklus i veličina sustava ne daje startne razlike među njima samo po sebi te ih je moguće uspoređivati.

Kao pokazatelj vremenskih promjena u nekom sustavu ili usporedbeni pokazatelj osjetljivosti planiranja i praćenja za neki sustav u odnosu na druge ili neki referentni sustav može nam poslužiti *koeficijent zadovoljenosti rokova* $\boldsymbol{K_{U_2}}$, prema izrazu (10)

$$\boldsymbol{K_{U_2}} = \frac{U_{2i}}{U_{2j}} \qquad K_{U_2} \leq, \geq 1 \tag{10}$$

gdje je: U_{2i} - uspoređivani stupanj zadovoljenosti rokova

U_{2j} - referentni stupanj zadovoljenosti rokova

3.2.3. Kriterij $\boldsymbol{U_3}$ – *efikasnost upravljanja zalihama*

Odabirući kriterij koji bi mogao najizraženije i dovoljno realno pokazati efikasnost planiranja i praćenja, u ovom slučaju procesa proizvodnje, ocijenjeno je da bi to trebalo biti efikasno upravljanje zalihama. Naime, troškovi koji proizlaze s naslova zaliha najveći su troškovi neposredno vezani za proces planiranja i praćenja proizvodnje, osjetno su veći od direktnih troškova procesa planiranja i praćenja, a veći su i od troškova uzrokovanih kašnjenjem isporuka. To znači da će i u slučaju velikog povećanja direktnih troškova procesa planiranja i praćenja (rad, pomagala, energija, i dr.) oni biti osjetno manji od samo manjeg povećanja troškova zaliha.

Zato je ovdje kao mjerilo efikasnosti, konkretno efikasnosti upravljanja zalihama $\boldsymbol{U_3}$ uzet *odnos* O_s *zaliha i potrošnje sirovina* u proizvodnji te *odnos zaliha gotovih proizvoda i isporučenih proizvoda* O_p, definirano izrazom

$$\boldsymbol{U_3} = \frac{1}{1/2 \cdot (O_p + O_s)} \tag{11}$$

gdje je:

$$O_p = \frac{\sum\sum(\bar{z}_p \,/\, \bar{x}_p)_{ij}}{12 \cdot p} \tag{12}$$

$$O_p = \frac{\sum\sum(\bar{z}_s \,/\, \bar{x}_{us})_{ij}}{12 \cdot s} \tag{13}$$

pri čemu je: $(\bar{z}_p)_{ij}$ – prosječno dnevno stanje zaliha proizvoda (j) u nekom mjesecu (i)

(i= 1, 2, 3 . . . . 12; j= 1,2,3……p)

$(\bar{x}_p)_{ij}$– količina isporučenog proizvoda (j) u nekom mjesecu (i)

(i= 1, 2, 3 . . . . 12; j= 1,2,3……p)

$(\bar{z}_s)_{ij}$– prosječno dnevno stanje zaliha sirovina (j) u nekom mjesecu (i)

(i= 1, 2, 3 . . . . 12; j= 1,2,3……s)

$(\bar{x}_{us})_{ij}$– količina utrošene sirovine (j) u nekom mjesecu (i)

(i= 1, 2, 3 . . . . 12; j= 1,2,3……s)

U izrazu (11) vrijednost svakog omjera je zbrojena s polovičnom vrijednošću kako bi svaki imao isti tretman, a također i zbog toga što bi u slučaju množenja tih omjera bilo $\boldsymbol{U_3}$=0 kada bi samo jedna od zaliha poprimila vrijednost 0 pa bi slika upravljanja zalihama bila lažna.

Stupanj efikasnosti upravljanja zalihama $\boldsymbol{U_3}$ poprima vrijednosti u sljedećim rasponima:

$$\boldsymbol{U_{3max}} = \infty \qquad (\bar{z}_p = 0; \quad \bar{z}_s = 0) \tag{14}$$

$$\boldsymbol{U_{3min}} = 0 \qquad (\bar{x}_p = 0; \quad \bar{x}_{us} = 0) \tag{15}$$

Vrijednost $\boldsymbol{U_3}$ biti će veća ako u odnosu na zalihe raste realizacija plasmana i proizvodnje tj. trošenje sirovina, pa u slučaju kada se proizvodnja teoretski odvija bez zaliha vrijednost $\boldsymbol{U_3}$ poprima maksimalnu vrijednost $\boldsymbol{U_{3max}} = \infty$.

Vrijednost $\boldsymbol{U_3}$ biti će minimalna i biti će $\boldsymbol{U_{3min}} = 0$ za slučaj kada nema trošenja sirovina u proizvodnji i kada nema isporuka proizvoda tj. kada je $\bar{x}_p = 0$ i $\bar{x}_{us} = 0$ a to znači da sustav ne funkcionira.

Možemo zaključiti da stupanj efikasnosti upravljanja zalihama $\boldsymbol{U_3}$ teži što većoj vrijednosti i u dobro organiziranom i automatiziranom proizvodnom sustavu može u praksi poprimati vrijednosti i veće od 10.

Opisani kriterij pogodan je zbog uopćenosti i bezdimenzionalnosti za usporedbu efikasnosti upravljanja zalihama kod različitih sustava u raznim vremenskim razdobljima a također je pogodan za utvrđivanje promjena u nekom sustavu ili usporedbe nekog sustava s referentnim sustavom putem *koeficijenta efikasnosti* $\boldsymbol{K_{U_3}}$, prema izrazu (16)

$$\boldsymbol{K_{U_3}} = \frac{U_{3i}}{U_{3j}} \qquad K_{U_2} \leq, \geq 1 \tag{16}$$

gdje je: U_{3i} - uspoređivani stupanj efikasnosti upravljanja zalihama

U_{3j} - referentni stupanj efikasnosti upravljanja zalihama

3.2.4. Sintetski kriterij ***U*** – *uspješnost planiranja i praćenja*

S aspekta ukupne ocjene planiranja i praćenja nekog procesa nužno je da on bude uspješan po više kriterija, odnosno svim odabranima, što u ovom slučaju znači da bi trebalo imati velik stupanj osjetljivosti i zadovoljenost rokova uz što veću efikasnost upravljanja zalihama.

Prema izrazu (17) ocjena planiranja i praćenja promatranog procesa u odabranom sustavu može se ocijeniti sintetskim kriterijem **U** - *uspješnost planiranja i praćenja*

$$\boldsymbol{U = U_1 \cdot U_2 \cdot U_3} \tag{17}$$

Eventualno ponderiranje pojedinih kriterija u sklopu sintetskog kriterija nije ovdje posebno razmatrano već je procijenjeno da će zbog svog većeg raspona kriterij efikasnost upravljanja zalihama $\boldsymbol{U_3}$ imati veći značaj u sklopu sintetskog kriterija uspješnost planiranja i praćenja, a što je s vrijednosnog aspekta tog kriterija ispravno.

Izraz (17) za sintetski kriterij uspješnosti je logičan jer se pojedinačni kriteriji nadopunjuju s aspekta ocjenjivanja u smislu što cjelovitijeg ocjenjivanja uspješnosti planiranja i praćenja a isti su i logički povezani po svojem djelovanju.

Stupanj uspješnosti planiranja i praćenja $\boldsymbol{U}$ poprima vrijednosti u rasponima kako slijedi:

$$\boldsymbol{U_{max}}=\infty \quad (\boldsymbol{U_{1max}}=1;\ \boldsymbol{U_{2max}}=1;\ \boldsymbol{U_{2max}}=\infty) \tag{18}$$

$$\boldsymbol{U_{min}}=0 \quad (\boldsymbol{U_{1min}}=0;\ \boldsymbol{U_{2min}}=0;\ \boldsymbol{U_{3min}}=0) \tag{19}$$

Prema izrazu (19) stupanj uspješnosti imati će minimalnu vrijednost $\boldsymbol{U_{min}}$=0 ako samo jedan od pojedinačnih kriterija poprimi vrijednost 0 a maksimalnu vrijednost $\boldsymbol{U_{max}}=\infty$ će imati ako pojedinačni kriterij $\boldsymbol{U_3}$ poprimi svoju maksimalnu vrijednost ∞.

I ovaj sintetski kriterij pogodan je zbog uopćenosti i bezdimenzionalnosti za usporedbu uspješnosti planiranja i praćenja kod različitih sustava u raznim vremenskim razdobljima a također je pogodan za utvrđivanje promjena u nekom sustavu ili usporedbe nekog sustava s referentnim sustavom putem *koeficijenta uspješnosti* K_U prema izrazu (20)

$$\boldsymbol{K_U} = \frac{U_i}{U_j} \qquad K_U \leq, \geq 1 \tag{20}$$

gdje je: U_i - uspoređivani stupanj uspješnosti planiranja i praćenja

U_j - referentni stupanj uspješnosti planiranja i praćenja

3.3. Model prilagodljivog planiranja i praćenja

Obzirom na postavljenu hipotezu ovog istraživanja i utvrđene ključne probleme planiranja i praćenja proizvodnje prvo će se pokušati istražiti utjecaj modela – načina planiranja i praćenja na uspješnost i prilagodljivost proizvodnog sustava u uvjetima dinamičnih promjena u okruženju i samom proizvodnom sustavu. Problem optimizacije u procesu planiranja i praćenja proizvodnje istražiti će se nakon tog dijela istraživanja pa se može reći da će ovo istraživanje obuhvatiti dva segmenta procesa planiranja i praćenja:

1. **način izvođenja procesa** planiranja i praćenja u funkciji uspješnosti i prilagodljivosti proizvodnog sustava
2. **optimizacija planova** proizvodnje u uvjetima dinamičnih promjena

Fleksibilni i prilagodljivi proces planiranja i praćenja proizvodnje treba omogućiti da se u što većoj mjeri postignu planirani rezultati i da se istovremeno proizvodni sustav u mogućoj mjeri što više prilagodi promjenama, a da se to bude izvedeno na efikasan i uspješan način.

Naime, kako su rezultati proizvodnog procesa najvećim dijelom posljedica načina i efikasnosti vođenja i realizacije procesa operativnog planiranja i praćenja, zasnovanom na podacima prodaje, nabave i proizvodnje, dobiveni rezultati i ocjene efikasnosti proizvodnje trebaju biti i ocjene uspješnosti operativnog planiranja i praćenja proizvodnje.

U tu svrhu postavljen je model za istraživanje, a koji uključuje:

a. model načina planiranja i praćenja proizvodnje
b. faktorski plan pokusa
c. model oponašanja
d. analiza varijance
e. model korektivne optimizacije

Ovdje se zapravo namjerava istražiti odabrani model načina planiranja i praćenja proizvodnje primjenom faktorskog plana pokusa, modela oponašanja i analize varijance kako bi se dobile podloge za modeliranje procesa planiranja i praćenja proizvodnje. Nakon toga bi se razradio model korektivne optimizacije planova proizvodnje i time potvrdio model prilagodljivog planiranja i praćenja proizvodnje a uz to i postavljeni ciljevi i hipoteza ovog istraživanja.

3.3.1. Model procesa planiranja i praćenja

U ovom istraživanju osmišljen je i pripremljen jedan fleksibilni i prilagodljivi model planiranja i praćenja proizvodnje koji je nazvan **klizno planiranje i praćenje** i koji je shematski prikazan na slici 6. Takav način odvijanja procesa planiranja i praćenja proizvodnje treba omogućiti da se proizvodni sustav što uspješnije prilagođava promjenama koje se intenzivno zbivaju u okruženju, uključivo i promjene u samom proizvodnom sustavu.

Osnovni princip kliznog planiranja i praćenja zasniva se na periodičkom usklađivanju sadržaja i aktivnosti vezanih za sve nivoe operativnih planova. Pri tome se svaki od njih korigira i usklađuje s promjenama koje se zbivaju u vremenu njihovog nižeg plana za sljedeće vremensko razdoblje trajanja plana, ne nužno i kalendarski. To znači da će, prema prikazanom primjeru na slici 6., korekcije i usklađivanja operativnih planova proizvodnje odvijati po sljedećoj dinamici:

a. osnovni operativni plan - mjesečni (OP) nakon isteka vremena $(T_k)_o$, odnosno vremena trajanja njemu nižeg, terminskog plana – tjednog plana (TP)

b. viši operativni plan – kvartalni (VP) nakon isteka vremena $(T_k)_v$, odnosno vremena trajanja njemu nižeg, osnovnog operativnog plana – mjesečnog plana (OP)

c. najviši operativni plan – godišnji (SVP) nakon isteka vremena $(T_k)_g$, odnosno vremena trajanja njemu nižeg, kvartalnog plana (VP)

Naravno, vremenska razdoblja pojedinih nivoa operativnih planova biti će različita u raznim proizvodnim sustavima, ovisno o predmetima proizvodnje, složenosti tehnologije, uvjetima u okolini-tržištu i drugim faktorima.

Također je važno napomenuti da se ovdje ne radi o interventnim korekcijama planova u slučaju promjena ili poremećaja već se sustavno i na definirani, propisani način u određenim vremenskim razmacima vrši korekcija i usklađivanje svih operativnih planova proizvodnje temeljem novih ulaznih podataka iz okruženja i samog sustava.

Kliznim planiranjem i praćenjem osigurava se da se mogu obavljati korekcije planova, a da se bitno ne narušava polazni plan već se isti korigira i usklađuje s promjenama u mogućoj mjeri. To znači da se npr. promjene koje se dogode u razdoblju $(T_k)_o$ uključuju u korigirani osnovni operativni plan (OP)' ako je to moguće i potrebno, dok se u suprotnom te informacije razvstavaju za neki od sljedećih korekcija planova.

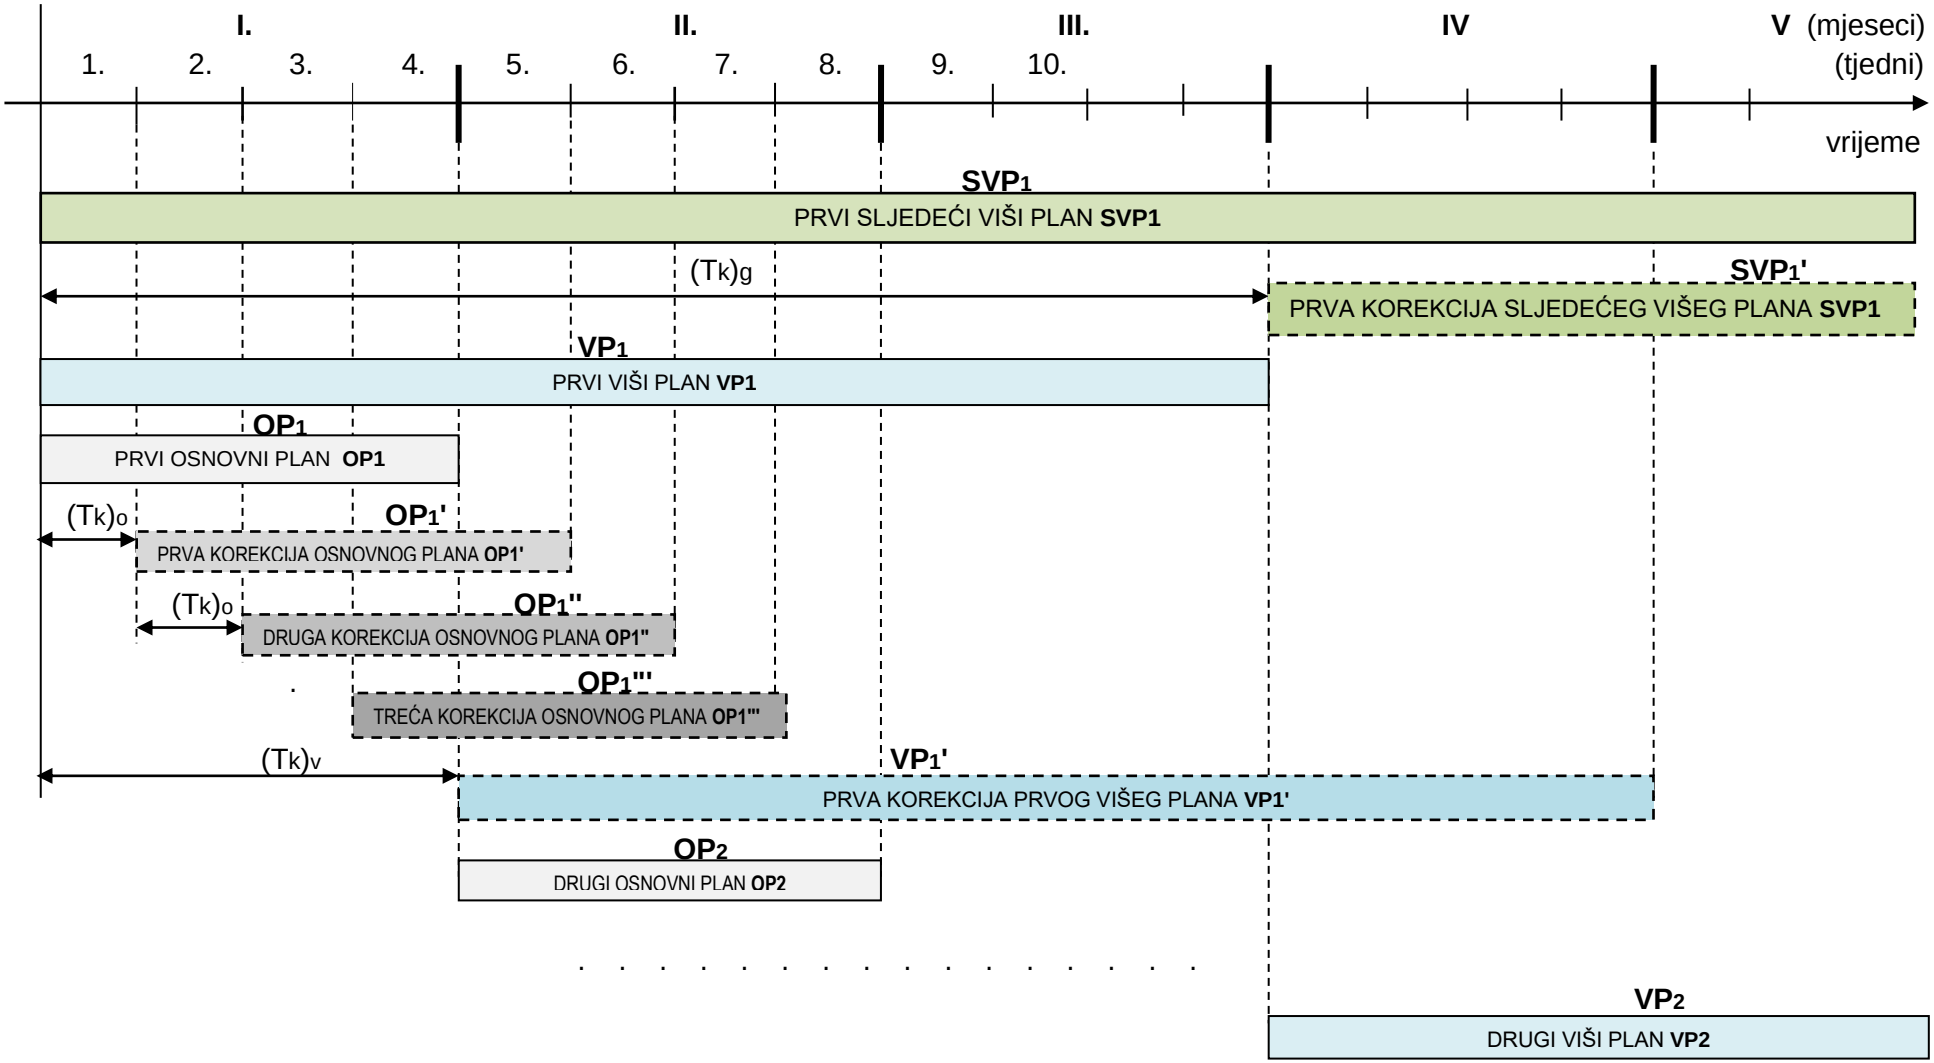

Slika 6. *Shematski prikaz principa kliznog planiranja i praćenja*

Istovremeno se, istekom razdoblja korekcije višeg plana $(T_k)_v$, obavlja korekcija i usklađivanje sljedećeg višeg plana $(VP_1)'$, a analogno tome istekom razdoblja korekcije sljedećeg višeg plana $(T_k)_g$ vrši se korekcija i usklađivanje sljedećeg višeg plana $(SVP_1)'$, itd.

Razdoblje korekcije višeg plana jednako je planskom razdoblju sljedećeg nižeg plana i tako redom za svaki nivo planova čime se osigurava kontinuitet planiranja i povezivanje sadržaja planova višeg i nižeg reda.

Pri tome se u nove, korigirane i usklađene planove unose nova rješenja zasnovana na podacima iz svih povezanih procesa, i to:

1. Prodaja – podaci o vrstama i količinama potražnje, rokovi isporuke i dr.
2. Nabava – podaci o potrebnim i raspoloživim repromaterijalima, rokovi dobave i dr.
3. Proizvodnja – podaci o kapacitetima i dr.
4. Planiranje i praćenje – ukupni podaci za korekcije i usklađivanja planova, aktivnosti i uvjeti potrebni za izvršenje planova i dr.

To konkretno podrazumijeva da se, obzirom na promjene u okruženju i samom sustavu, putem kliznog načina planiranja i praćenja proizvodnje provjeravaju postojeći sadržaji planova po svim obilježjima te kreiraju novi sadržaji planova uz njihovo međusobno usklađivanje i optimiranje. Sve korekcije i promjene planova obavljaju se sukladno mogućnostima proizvodnog i ostalih navedenih povezanih sustava a promjene rasporeda u tekućoj proizvodnji izvodi se samo ako to dozvoljavaju prethodno definirane postavke realizacije zahtjeva, odnosno radnih naloga.

Zato se može reći da na proces i rezultate planiranja i praćenja proizvodnje djeluje veći broj utjecajnih faktora koji proizlaze iz strukture i procesa proizvodnog sustava, njegovog predmeta i tehnologije rada i parametara iz okruženja. Proces planiranja i praćenja proizvodnje intenzivno je povezan s procesom proizvodnje, a također ima učestale i stalne veze sa procesima prodaje i nabave koja su spona poslovnog sustava s okruženjem. Stoga se može očekivati da će iz tih procesa biti i određen broj utjecajnih faktora koji djeluju na efikasnost proizvodnje i uspješnost planiranja i praćenja.

Koji će biti glavni utjecajni faktori na uspješnost planiranja i praćenja u nekom proizvodnom sustavu uvijek će trebati za svaki pojedini slučaj zasebno utvrditi, a može se očekivati da će isti utjecajni faktori različito djelovati u različitim proizvodnim sustavima i njihovim okruženjima.

3.3.2. Faktorski plan pokusa

Djelovanje utjecajnih faktora može se efikasno odrediti primjenom **faktorskog plana pokusa** čiji se rezultati mogu podvrgnuti analizi varijance pa će se na taj način odrediti značaj tretiranih utjecajnih faktora. Faktorski plan pokusa je svaki pokus sa dva ili više faktora koji se istovremeno ispituju putem njihovog variranja, odnosno promjenama nivoa tretiranih faktora, pa je tako ta metoda pogodna i za ispitivanje utjecajnih faktora na uspješnost procesa planiranja i praćenja proizvodnje.

Faktor predstavlja svaki uvjet pokusa koji se kao takav može ispitivati, a u jedan faktorski pokus uključuju se svi faktori u svim kombinacijama njihovog tretmana. Putem faktorskog plana pokusa ispituju se promjene neke pojave-događaj-zakonitosti uslijed primjene različitog tretmana datog faktora. Uz to se ispituje i kako neka pojava-događaj-zakonitost djeluje u kombinacijama sa promjenama u tretmanu drugih faktora. Ako su promjene u tretmanu nekog faktora od utjecaja na promjene kod drugih faktora, tada se govori o interakciji ispitivanih faktora.

Osnovni problem u radu s pokusima je utvrđivanje i uspoređivanje dobivenih rezultata a zbog mogućnosti utjecaja nekontroliranih faktora potrebno je ponavljanje pokusa. Naime, kod pokusa postoje dva oblika varijacije:

a. varijacije koje su rezultat primjenjenog tretmana
b. varijacije koje proizlaze iz djelovanja nekotroliranih činitelja – greške pokusa

Slučajne varijacije treba svesti na minimum kako bi djelovanje tretmana došlo do većeg izražaja pa zato pokuse treba pažljivo planirati, ponavljati i kontrolirati.

S obzirom da je izuzetno teško objasniti dobivene rezultate u pokusima sa više od tri faktora, pogotovo je teško analizirati inteakcije trećeih i viših redova, a broj utjecajnih faktora na planiranje i praćenje je relativno velik, za ovo će se istraživanje koristiti faktorski plan pokusa $\mathbf{2^5}$ čija je tablica prikazana na slici 7. Utjecajni faktori označeni s velikim slovima A, B, C, D i E a broj uz svaki faktor-slovo simolizira nivo u pokusu, 1. ili 2. U svakom dijelu tablice data je malim slovima faktora (**a, b, c, d, e**) oznaka pokusa koja govori koji su faktori u tom pokusu na 2. nivou te brojčana oznaka od 1 do 32 za redni broj pokusa.

Unutar tablice se navode vrijednosti $\boldsymbol{y_{ijklm}}$ dobivene odgovarajućim pokusom, a prema odabranom kriteriju, gdje mala slova i, j, k, l, m uz dobivenu vrijednost pokusa **y** mogu imati vrijednost 1 ili 2, ovisno na kojem je nivou svaki od faktora u nekom od pokusa.

y_{ijklm}			B_1				B_2			
			A_1		A_2		A_1		A_2	
E_1	D_1	C_1	1	(1) y_{11111}	2	a y_{21111}	3	b y_{12111}	4	ab y_{22111}
		C_2	5	c y_{11211}	6	ac y_{21211}	7	bc y_{12211}	8	abc y_{22211}
	D_2	C_1	9	d y_{11121}	10	ad y_{21121}	11	bd y_{12121}	12	abd y_{22121}
		C_2	13	cd y_{11221}	14	acd y_{21221}	15	bcd y_{11221}	16	abcd y_{11221}
E_2	D_1	C_1	17	e y_{11112}	18	ae y_{21112}	19	be y_{12112}	20	abe y_{22112}
		C_2	21	ce y_{11212}	22	ace y_{21212}	23	bce y_{12212}	24	abce y_{22212}
	D_2	C_1	25	de y_{11122}	26	ade y_{21122}	27	bde y_{12122}	28	abde y_{22122}
		C_2	29	cde y_{11222}	30	acde y_{21222}	31	bcde y_{12222}	32	abcde y_{22222}

Slika 7. *Tablica faktorskog plana pokusa* $\boldsymbol{2^5}$ *za istraživanje*

3.3.3. Model za oponašanje

Da bi uopće dobili ulazne veličine po odabranim kriterijima i mjerilima za faktorski plan pokusa i analizu varijance, biti će potrebno odabrane pokazatelje za neki proizvodni sustav i odabrane, najznačajnije utjecajne faktore tretirati na drugom nivou. Drugi nivo svakog odabranog faktora za tretiranje odrediti će se maksimalno objektiviziranom i argumeniranom procjenom koja se pod određenim uvjetima može postići u promatranom proizvodnom sustavu.

Stoga će drugi model za istraživanje biti **model oponašanja** koji će, uz primjenu određenih stanja odabranih utjecajnih faktora, dati rezultate pokusa gdje je svako oponašanje jedan pokus u sklopu faktorskog plana pokusa $\mathbf{2^5}$. S obzirom na odabrane granice istraživanja, model treba obuhvatiti stanja, parametre i aktivnosti s algoritmima i zakonitostima za procese koji će se oponašati.

Model za oponašanje treba uz primjenu određenih stanja odabranih utjecajnih faktora dati rezultate pokusa gdje je svako oponašanje jedan pokus u sklopu faktorskog plana pokusa $\mathbf{2^5}$. Ti se rezultati nakon toga obrađuju u skladu s elementima izraza za odabrane pokazatelje uspješnosti planiranja i praćenja. Obzirom na odabrane granice istraživanja, model treba obuhvatiti stanja, parametre i aktivnosti s algoritmima i zakonitostima za procese operativnog planiranja i praćenja, prodaje, nabave i proizvodnje. Pri tome trebaju biti uzeti u obzir svi potrebni elementi prema utvrđenom stanju u promatranom objektu, kako u smislu sadržaja tako i samog procesa koji se oponaša.

U modelu su izvršena potrebna pojednostavljenja aktivnosti pojedinih procesa, tako da su uzete samo ključne aktivnosti koje djeluju na podatke iz kojih će se kasnije obraditi pokazatelji uspješnosti planiranja i praćenja po odabranim kriterijima. Program za oponašanje napravljen je prema rješenju prilagođenom za ovo istraživanje, sa svim potrebnim operacijama i pripadajućim algoritmima. Pojednostavljeni i skraćeni prikaz blok-dijagrama oponašanja procesa planiranja i praćenja proizvodnje s ostalim tretiranim procesima prikazan je na slici 8.

Slika 8. *Skraćeni blok-dijagram programa za oponašanje procesa*

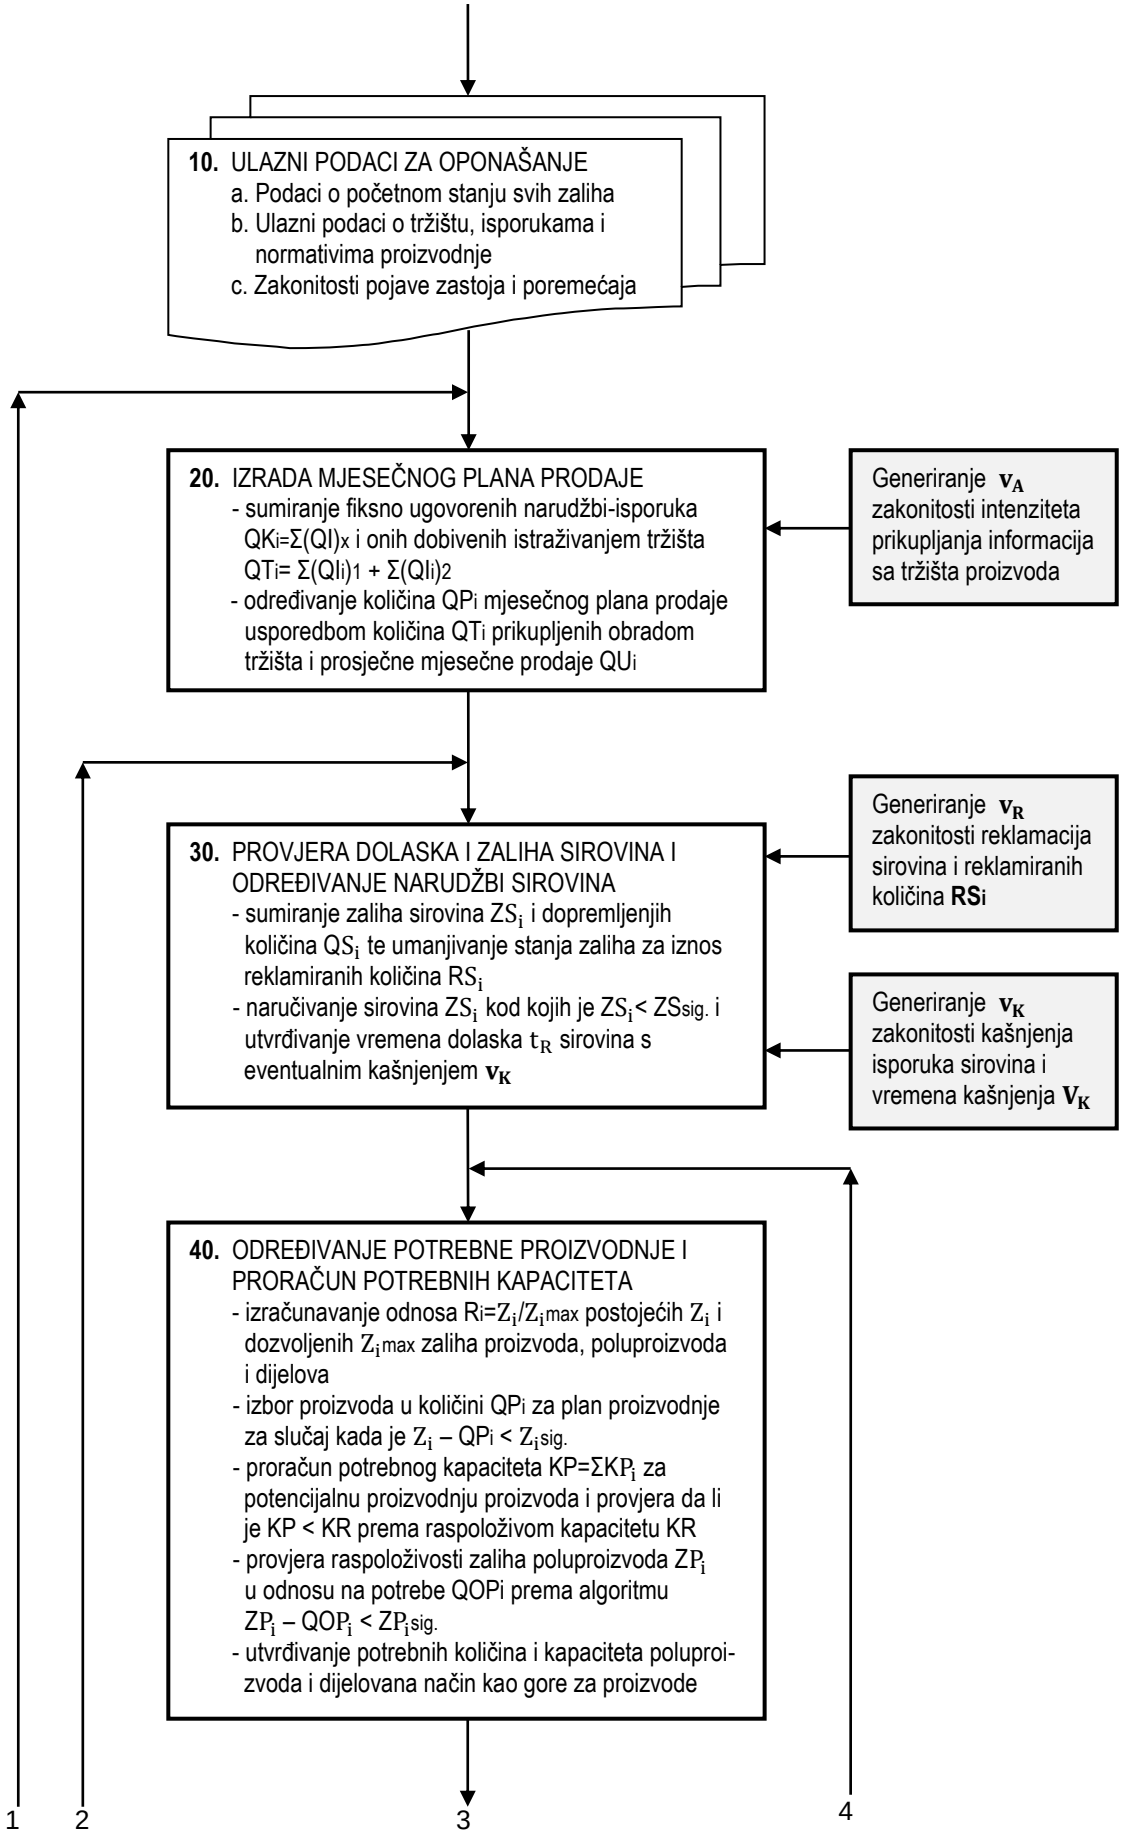

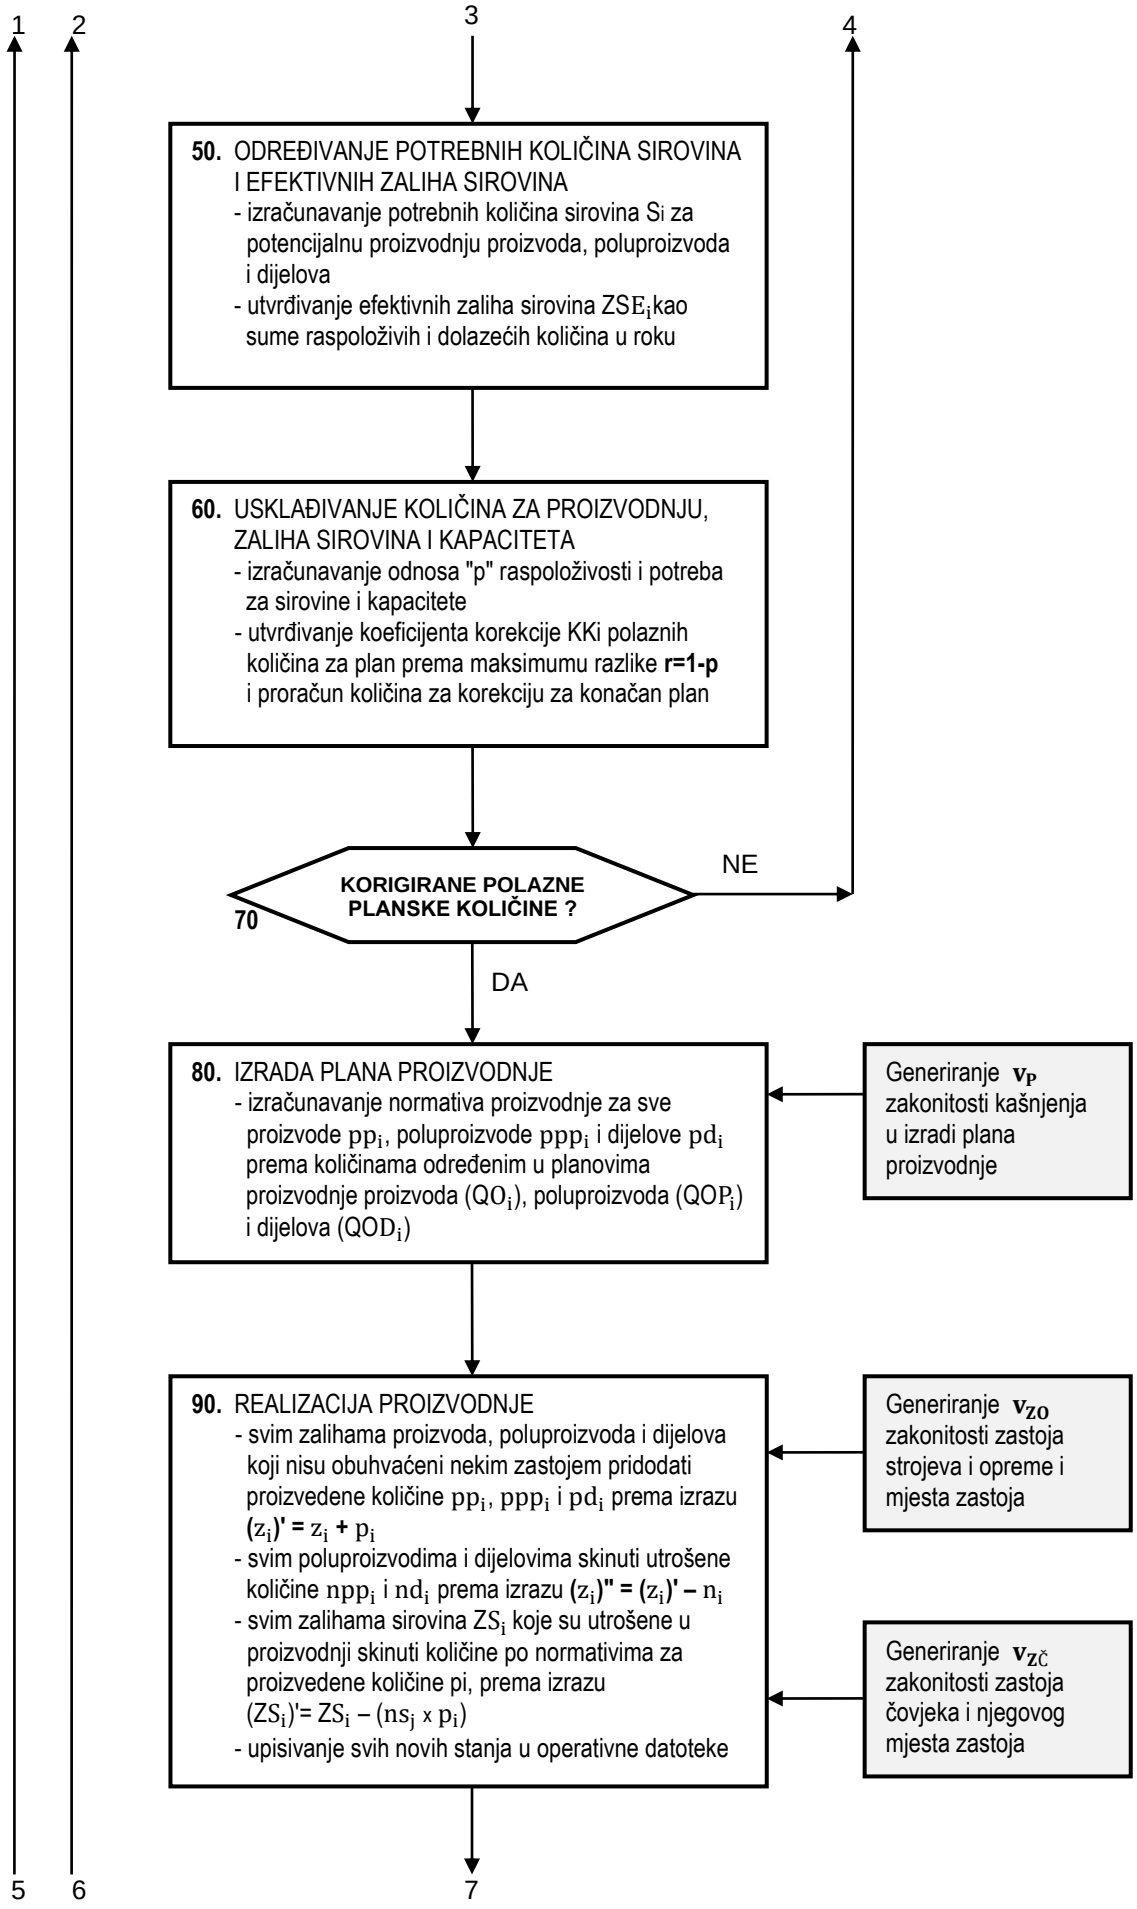
1
2
3
4
50. ODREĐIVANJE POTREBNIH KOLIČINA SIROVINA I EFEKTIVNIH ZALIHA SIROVINA
- izračunavanje potrebnih količina sirovina Si za potencijalnu proizvodnju proizvoda, poluproizvoda i dijelova
- utvrđivanje efektivnih zaliha sirovina ZSE_i kao sume raspoloživih i dolazećih količina u roku
60. USKLAĐIVANJE KOLIČINA ZA PROIZVODNJU, ZALIHA SIROVINA I KAPACITETA
- izračunavanje odnosa "p" raspoloživosti i potreba za sirovine i kapacitete
- utvrđivanje koeficijenta korekcije KKi polaznih količina za plan prema maksimumu razlike **r=1-p** i proračun količina za korekciju za konačan plan
KORIGIRANE POLAZNE PLANSKE KOLIČINE ?
70
NE
DA
80. IZRADA PLANA PROIZVODNJE
- izračunavanje normativa proizvodnje za sve proizvode pp_i, poluproizvode ppp_i i dijelove pd_i prema količinama određenim u planovima proizvodnje proizvoda (QO_i), poluproizvoda (QOP_i) i dijelova (QOD_i)
Generiranje v_P zakonitosti kašnjenja u izradi plana proizvodnje
90. REALIZACIJA PROIZVODNJE
- svim zalihama proizvoda, poluproizvoda i dijelova koji nisu obuhvaćeni nekim zastojem pridodati proizvedene količine pp_i, ppp_i i pd_i prema izrazu $(z_i)' = z_i + p_i$
- svim poluproizvodima i dijelovima skinuti utrošene količine npp_i i nd_i prema izrazu $(z_i)'' = (z_i)' - n_i$
- svim zalihama sirovina ZS_i koje su utrošene u proizvodnji skinuti količine po normativima za proizvedene količine pi, prema izrazu $(ZS_i)' = ZS_i - (ns_j \times p_i)$
- upisivanje svih novih stanja u operativne datoteke
Generiranje v_{ZO} zakonitosti zastoja strojeva i opreme i mjesta zastoja
Generiranje $v_{ZČ}$ zakonitosti zastoja čovjeka i njegovog mjesta zastoja
5
6
7

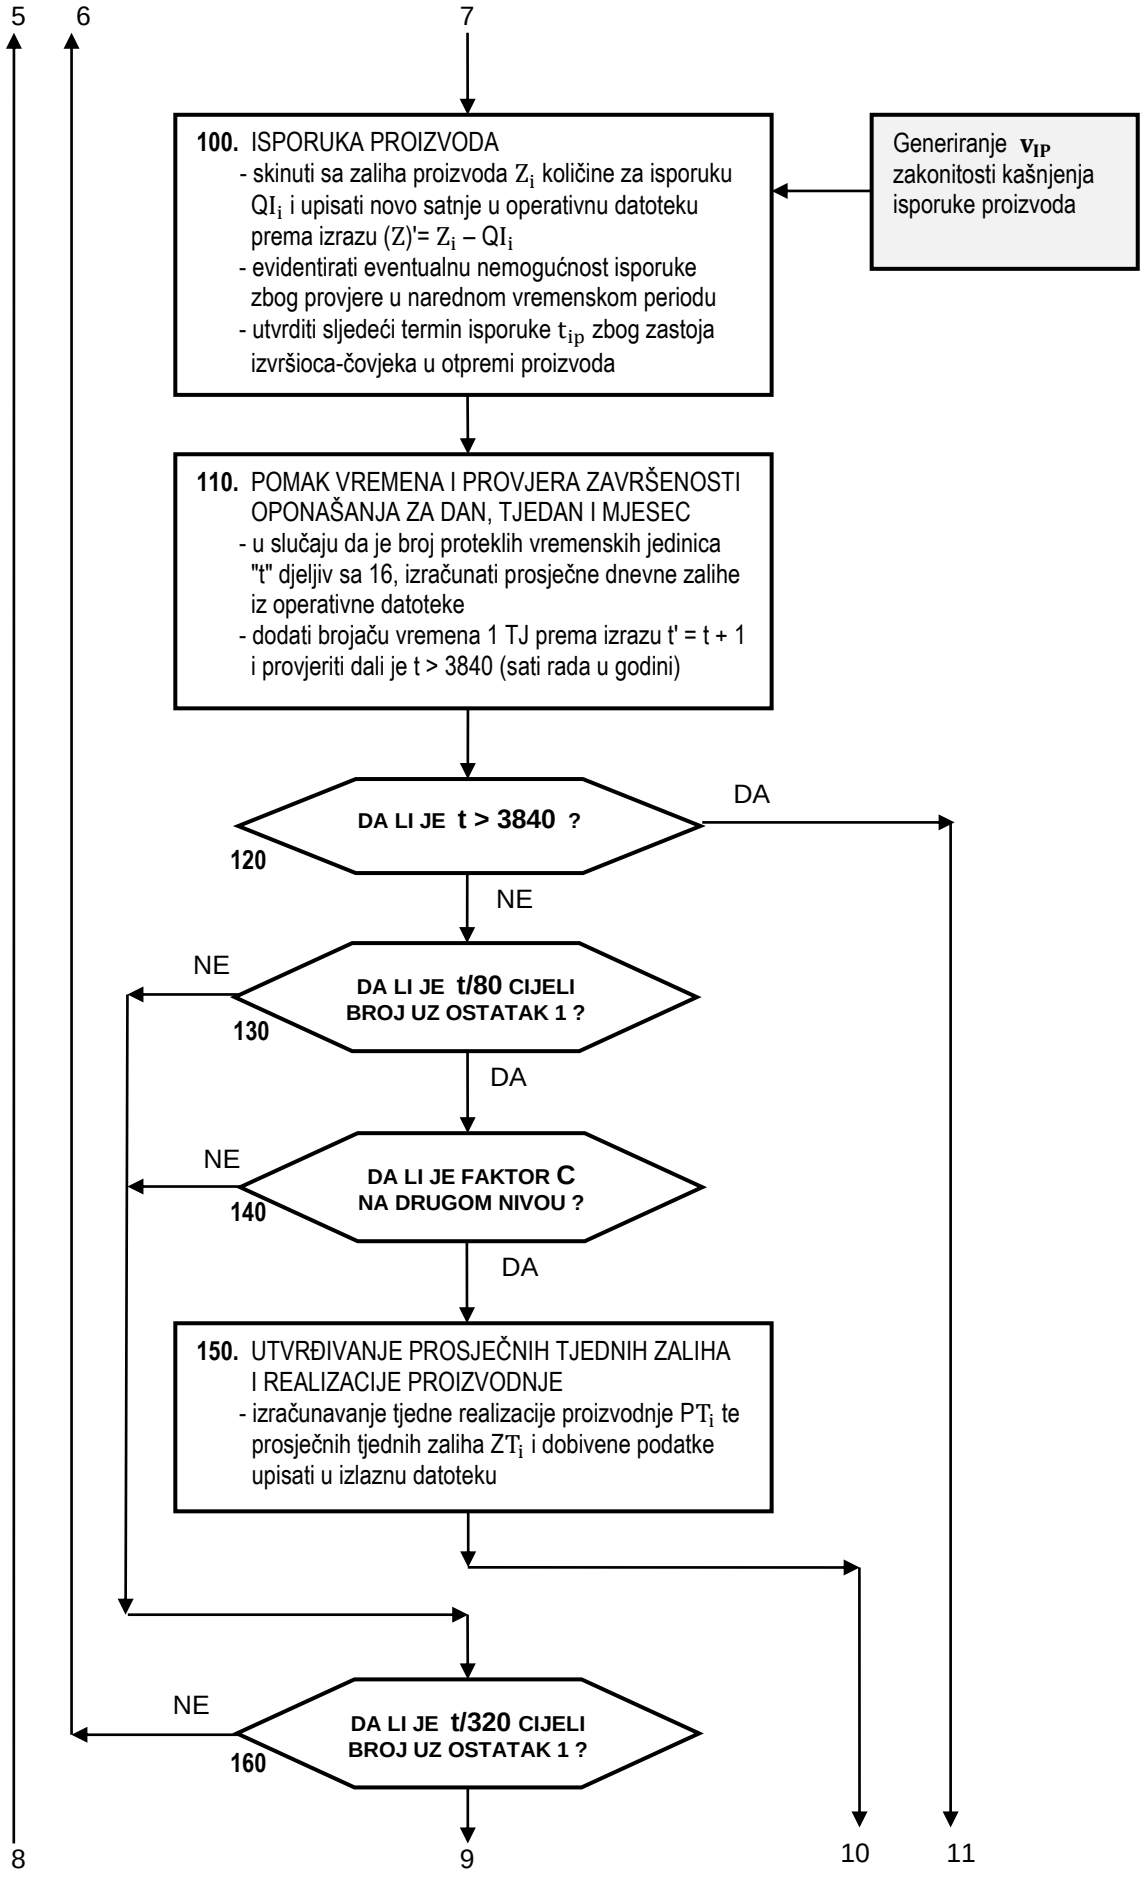
5
6
7
100. ISPORUKA PROIZVODA
- skinuti sa zaliha proizvoda Z_i količine za isporuku QI_i i upisati novo satnje u operativnu datoteku prema izrazu $(Z)' = Z_i - QI_i$
- evidentirati eventualnu nemogućnost isporuke zbog provjere u narednom vremenskom periodu
- utvrditi sljedeći termin isporuke t_{ip} zbog zastoja izvršioca-čovjeka u otpremi proizvoda
Generiranje v_{IP} zakonitosti kašnjenja isporuke proizvoda
110. POMAK VREMENA I PROVJERA ZAVRŠENOSTI OPONAŠANJA ZA DAN, TJEDAN I MJESEC
- u slučaju da je broj proteklih vremenskih jedinica "t" djeljiv sa 16, izračunati prosječne dnevne zalihe iz operativne datoteke
- dodati brojaču vremena 1 TJ prema izrazu t' = t + 1 i provjeriti dali je t > 3840 (sati rada u godini)
DA LI JE t > 3840 ?
120
DA
NE
DA LI JE t/80 CIJELI BROJ UZ OSTATAK 1 ?
130
NE
DA
DA LI JE FAKTOR C NA DRUGOM NIVOU ?
140
NE
DA
150. UTVRĐIVANJE PROSJEČNIH TJEDNIH ZALIHA I REALIZACIJE PROIZVODNJE
- izračunavanje tjedne realizacije proizvodnje PT_i te prosječnih tjednih zaliha ZT_i i dobivene podatke upisati u izlaznu datoteku
DA LI JE t/320 CIJELI BROJ UZ OSTATAK 1 ?
160
NE
8
9
10
11

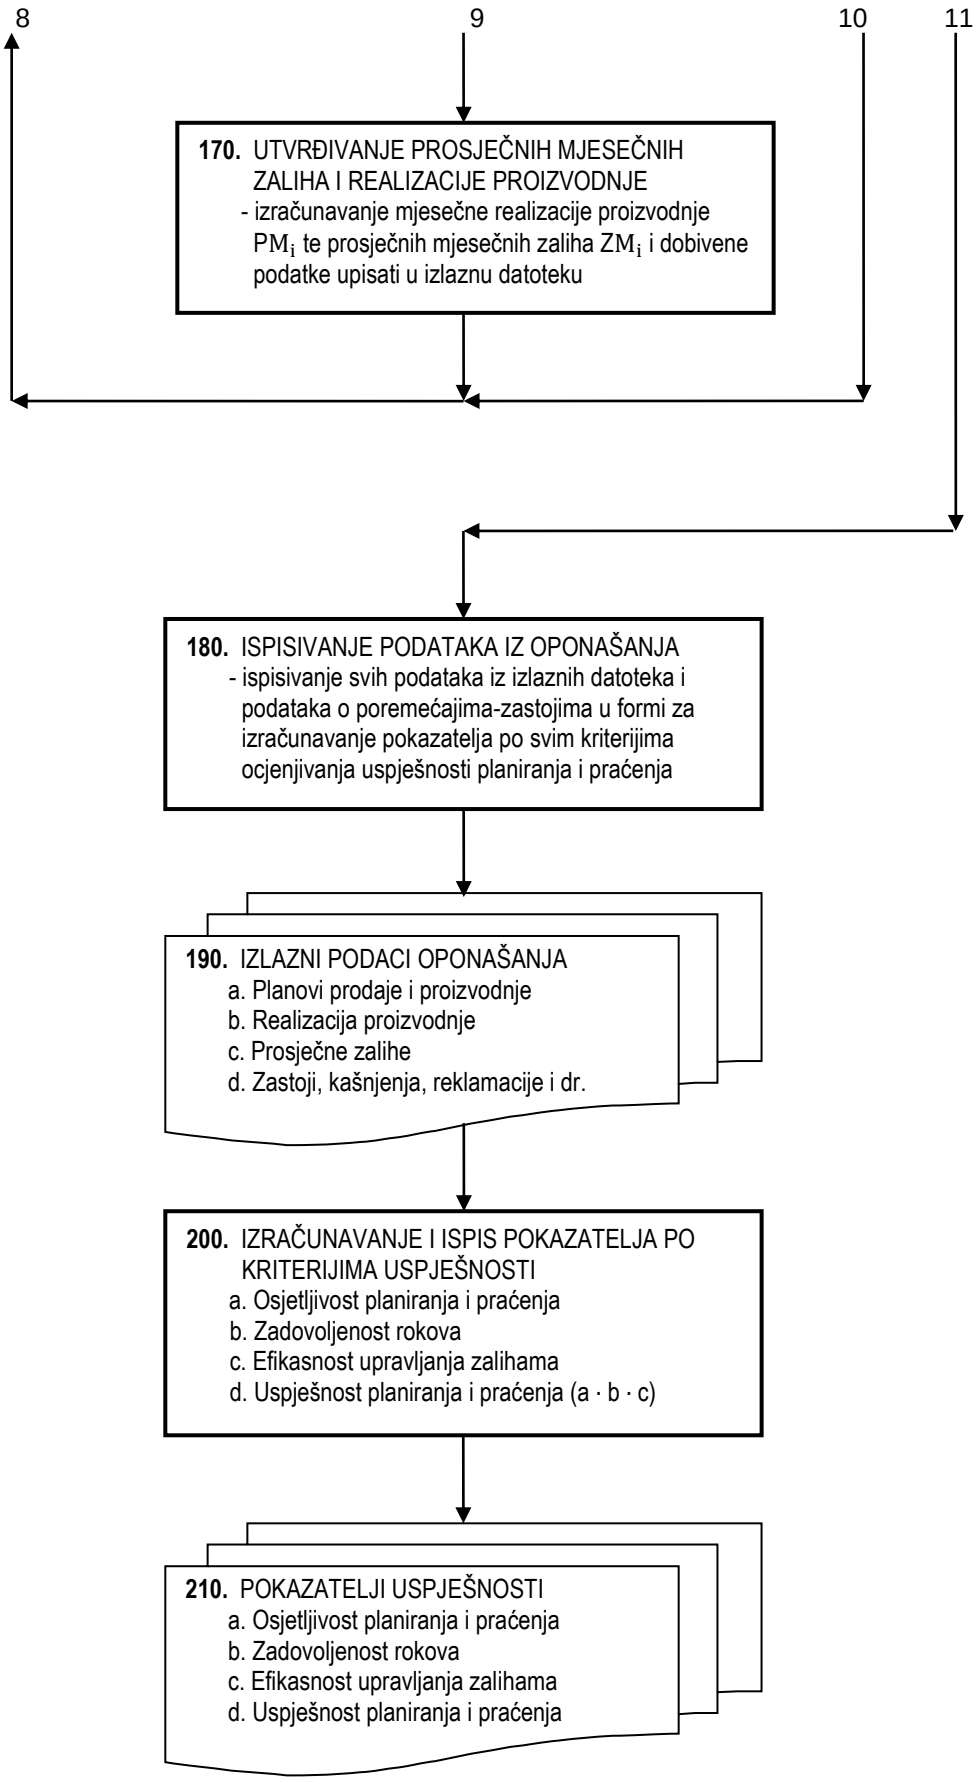
8
9
10
11
170. UTVRĐIVANJE PROSJEČNIH MJESEČNIH ZALIHA I REALIZACIJE PROIZVODNJE
- izračunavanje mjesečne realizacije proizvodnje PM_i te prosječnih mjesečnih zaliha ZM_i i dobivene podatke upisati u izlaznu datoteku
180. ISPISIVANJE PODATAKA IZ OPONAŠANJA
- ispisivanje svih podataka iz izlaznih datoteka i podataka o poremećajima-zastojima u formi za izračunavanje pokazatelja po svim kriterijima ocjenjivanja uspješnosti planiranja i praćenja
190. IZLAZNI PODACI OPONAŠANJA
a. Planovi prodaje i proizvodnje
b. Realizacija proizvodnje
c. Prosječne zalihe
d. Zastoji, kašnjenja, reklamacije i dr.
200. IZRAČUNAVANJE I ISPIS POKAZATELJA PO KRITERIJIMA USPJEŠNOSTI
a. Osjetljivost planiranja i praćenja
b. Zadovoljenost rokova
c. Efikasnost upravljanja zalihama
d. Uspješnost planiranja i praćenja (a · b · c)
210. POKAZATELJI USPJEŠNOSTI
a. Osjetljivost planiranja i praćenja
b. Zadovoljenost rokova
c. Efikasnost upravljanja zalihama
d. Uspješnost planiranja i praćenja

Kao ulazni veličine potrebno će biti pripremiti i koristiti sljedeće podatke:

01. podaci-stanja tržišta prodaje
02. pregled prosječne mjesečne prodaje proizvoda
03. podaci-stanja tržišta nabave
04. normativi utroška sirovina i dijelova za dijelove, poluproizvode i proizvode
05. normativi vremena proizvodnje dijelova, poluproizvoda i proizvoda
06. početna stanja zaliha sirovina
07. početne narudžbe sirovina
08. početna stanja zaliha proizvoda
09. početni normativi proizvodnje dijelova, poluproizvoda i proizvoda
10. sve zakonitosti zastoja i poremećaja

3.3.4. Analiza varijance

Analiza varijance treba omogućiti da se prethodno izvršenim faktorskim pokusima s parametrima dobivenim korištenjem odabranog modela oponašanja i obrađenih po definiranim kriterijima i mjerilima odredi nivo djelovanja odabranih utjecajnih faktora i njihovih interakcija

Kao znanstveni matematički postupak testiranja više od dvije sredine istog ili različitih osnovnih skupova, analiza varijance treba omogućiti da se iz totalne varijacije izdvoje varijacije između grupa kao rezultat djelovanja tretmana i varijacije unutar grupa kao rezultat slučajnih varijacija unutar svakog tretmana. Kada ne bi bilo djelovanja tretmana-faktora, razlike između totalne, međugrupne i unutargrupne varijacije imale bi slučajan karakter i bile bi rezultat varijabilnosti jedinica.

Kod analize pokusa je bitno saznati da li je razlika između tretmana slučajna ili je rezultat karakteristika tretmana. Ako su sve sredine jednake i potiču iz istog skupa, tada će količnik odnosa varijanci između grupa i unutar grupa biti manji od kritične vrijednosti u tablicama F-razdiobe, uz odgovarajući prag značajnosti, i obrnuto. Taj će količnik varijanci ujedno pokazati značajnost svakog faktora i interakcije i kvalitativni odnos značajnosti među njima.

3.3.5. Model korektivne optimizacije

Uz primjenu kliznog planiranja i praćenja potrebno je odabrati i odgovarajući model optimizacije planova prooizvodnje koji bi omogućavao dinamičnost i korektivnost u postupku optimizacije kako bi na taj način dobili **model prilagodljivog planiranja i praćenja proizvodnje**. Taj model treba omogućiti iznalaženje optimalnih planova i optimalnog procesa planiranja i praćenja na način da se u što većoj mjeri uzimaju u tretman promjene i poremećaji u sustavu i njegovom okruženju i optimiraju rješenja za takve situacije uz osiguranje prilagodljivosti i fleksibilnosti proizvodnog sustava. Drugim riječima, traži se model planiranja i praćenja koji se može u što većoj mjeri prilagoditi stvarnim, aktualnim uvjetima u sustavu i njegovom okruženju na optimalan način. Naime, u praksi se uvijek događaju manji ili veći poremećaji zbog kojih dolazi do odstupanja realizacije u odnosu na optimalno planirane rezultate a standardne metode i tehnike optimizacije nisu oblikovane na način koji omogućuje prilagodljivost i fleksibilnost proizvodnog sustava.

S obzirom na dinamičnost promjena u vremenu, sigurno je da kao metodu i tehniku optimiranja u procesu planiranja i praćenja treba koristiti neku od matematičkih modela dinamičkog programiranja jer je za probleme planiranja i praćenja vrijeme važan faktor.

No, kao i kod svih drugih matematičkih modela programiranja i kod svakog dinamičkog programiranja imamo uvjete i ograničenja po kojima takav matematički model funkcionira, a to uvijek manje ili više odstupa od stvarnosti jer se na izjestan način ona prilagođava modelu.

Drugi problem u primjeni matematičkih modela je njihova primjena na bazi zakonitosti i parametara iz bliže ili daljnje prošlosti te nemogućnost uzimanja u tretman većih i iznenadnih promjena u samom sustavu i njegovom okruženju. Tu sada dolazi do izražaja važnost stupnja pouzdanosti procesa u proizvodnom sustavu. To znači da će matematičko programiranje biti pouzdanije i realnije ako iz svakog procesa proizvodnog sustava dobivamo na vrijeme sve potrebne kvalitetne informacije. Međutim, i tada se ne mogu u potrebnoj mjeri u optimiranje uključiti informacije vezane za promjene i poremećaje u sustavu i njegovom okruženju.

To ukazuje na potrebu stvaranja modela koji će s jedne strane putem neke od metoda i tehnika matematičkog programiranja određivati optimalne planove za određeno vremensko razdoblje. Uz to će se moći na odgovarajući način najbolje reagirati na promjene i poremećaje koji se pojavljuju u datom trenutku, a važni su i značajno utječu na prethodno postavljena rješenja.

U slučaju da se u model dinamičkog programiranja želi uključiti i optimalno rješavanje situacija promjena i poremećaja po pojedinim dijelovima razdoblja za koje je prethodno dato najpovoljnije rješenje, moguće je postupiti na jedan od sljedeća dva načina:

A. Ponovo tretirati odabrano plansko razdoblje od momenta donošenja odluke o istom

B. Oponašanjem odrediti rješenje korekcije postojećeg plana

U slučaju korekcije postojećeg plana primjenom metoda i tehnika oponašanja, uz primjenu pouzdanih zakonitosti i parametara dobivenih spoznajama u praksi, veća je vjerojatnost da se neće postići željeni ili mogući nivo optimizacije. Zato je sigurnije da će se promjene u aktualnom planu izvršiti bezbolnije, s manje promjena u realizaciji i uz manje troškove korekcije planova u odnosu na prvi slučaj.

Model optimizacije kojim se uz primjenu oponašanja i postupka kliznog planiranja i praćenja korigiraju planovi dobiveni metodama i tehnikama dinamičkog programiranja može se nazvati **diskretno korektivno dinamizirano optimiranje**.

Takvo korektivno optimiranje, sukladno prikazu procesa kliznog planiranja i praćenja na slici 6., obuhvaća moguće uvrštavanje u postupak optimizacije promjena u okruženju ili samom sustavu koje su se dogodile u vremenu $(T_k)_o$ tijekom izvođenja aktualnog osnovnog operativnog plana proizvodnje **OP_1**. Pri tome se dio promjena može uključiti u diskretno korektivno dinamičko optimiranje tekućeg operativnog plana, a dio promjena biti će uključen u optimizaciju sljedećeg operativnog plana, ovisno o karakteru promjena i mogućnostima proizvodnog sustava.

To znači da će se polazni optimalni planovi P_1, P_2, ... P_k za vremensko razdoblje T korigirati i pretvarati u planove $(P_1)'$, $(P_2)'$, ... $(P_k)'$ istekom svakog vremena korekcije T_k te će rješenje za i-to razdoblje i plan $(P_i)'$ biti definirano kao vektor u izrazu (21)

$$\overrightarrow{X_{(i)}} = (x_i \pm \Delta x_i) \qquad (21)$$

gdje je Δx_i dio optimalne korekcije prethodnog plana dobivene oponašanjem.

Sljedeće optimiranje višeg plana VP_1', po modelu kliznog planiranja i praćenja na slici 6., izvoditi će se dinamičkim programiranjem gdje će biti uključen i dio promjena koji nije obuhvaćen prethodnim korekcijama prijašnjeg operativnog plana.

S obzirom da će izbor rješenja modela optimizacije za planiranje i praćenje proizvodnje biti najvećim dijelom uvjetovan rezultatima dobivenim na prethodnim dijelovima modela za istraživanje, model korektivne optimizacije detaljno će se definirati u zadnjoj fazi istraživanja.

4. ISTRAŽIVANJE NA PRIMJERU

Neposredno istraživanje modela prilagodljivog planiranja i praćenja proizvodnje putem ispitivanja kliznog planiranja i praćenja uz korištenje modela oponašanja te plana pokusa i analize varijance obaviti će se na jednom konkretnom primjeru iz prakse za koji su bili raspoloživi podaci za neposredno istraživanje, a to je proizvodnja emajliranog posuđa.

Radi se o starijim rezultatima iz jednog razvojnog projekta od prije 25 godina koji su zbog svoje kompletnosti pogodni za korištenje u ovom istraživanju, a tipičan je primjer proizvodne tvrtke srednje veličine sa serijskom proizvodnjom te isporukama kombinirano, sa zaliha i po narudžbi. S obzirom da će se u daljnjem istraživanju na modelu primjenom metode oponašanja i faktorskog plana pokusa sa analizom varijance utjecaji i zaključci određivati usporedbom tretiranih nivoa istih faktora u istom sustavu, starost podataka, kao ni vrsta proizvodnje, ne bi smjela imati utjecaja na dobivene rezultate i zaključke.

Snimljeni podaci obuhvaćaju razdoblje od pet godina i uključuju sve relevantne informacije i pokazatelje za procese proizvodnje, prodaje, nabave i operativnog planiranja i praćenja temeljem kojih je bilo moguće dobiti uvid u postojeće stanje navedenih procesa i ocijeniti aktualnu uspješnost planiranja i praćenja proizvodnje prema odabranim kriterijima i mjerilima navedenim u poglavlju 3.2. ovog rada. Snimanje je obavljeno obradom radne dokumentacije i izvještaja iz proizvodnje te putem intervjua sa zaposlenicima kako bi se za potreban dio podataka mogle dobiti relevantne procjene.

Proučavanjem snimljenog stanja utvrđeni su utjecajni faktori na dobivene rezultate po svakom od navedenih, korištenih kriterija i mjerila, a među njima su za daljnje istraživanje odabrani najznačajniji utjecajni faktori.

S obzirom da je velik broj utjecajnih faktora bilo teško tretirati, njihov je broj sveden na prihvatljivu mjeru putem kvantitatvivne i kvalitativne ocjene njihovog djelovanja, pogodnosti za daljnje tretiranje i mogućnosti djelovanja na njihov utjecaj.

U daljnjem tekstu ovog dijela rada navode se svi sadržaji snimanja stanja na odabranom primjeru od kojih su najvažniji sastavni dio teksta a ostatak je dat u obliku priloga ovom radu.

4.1. Stanje u proizvodnji

Proizvodnja emajliranog posuđa je relativno jednostavna serijska proizvodnja koja se sastoji od 11 grupa tehnoloških operacija, a asortiman proizvodnje čini oko 250 proizvoda koji imaju 2-12 pozicija koje prolaze kroz sljedeće faze proizvodnje:

1. rezanje lima na škarama
2. duboko izvlačenje na prešama
3. elektrootporno zavarivanje
4. obrezivanje viška materijala
5. montaža prstenastog obruba od nehrđajućeg čelika
6. odmašćivanje limenih poluproizvoda
7. nanošenje emajla na kotlovima
8. sušenje proizvoda
9. pečenje emajla na proizvodu
10. montaža ručki i dijelova
11. pakiranje

Zbog lakšeg snimanja i kasnijeg korištenja podataka, proizvodni asortiman je svrstan u grupe po sličnosti proizvodnje te veličini i težini, a prosječna godišnja proizvodnja i prodaja prikazana je u tablici 1.

Shematski prikaz toka proizvodnje navedenih grupa proizvoda prikazan je na slici 9. na način da se krenulo od dijelova proizvoda te su prikazane faze njihove proizvodnje do realizacije gotovog proizvoda, sve prikazano po radnim mjestima – strojevima i opremi.

Tablica 1. *Realizacija prodaje i proizvodnje po grupama proizvoda*

Naziv grupe proizvoda	Oznaka	Prodane količine kom./god.	Prodane količine kom./mjes.	Učešće (%) u prodaji	Posebne naznake dimenzije	Posebne naznake boje, dekor
1. Stalna, značajna kooperacija	P1	171.000	14.250	6,27	do Φ520	crna
2. Povremene usluge i kooperacija	P2	248.000	20.667	9,10	max.1000x500	razna
3. Rekord posuđe - manje	P3	625.000	52.083	22,93	do Φ220	razna
4. Rekord posuđe – veće	P4	751.000	62.583	27,55	> Φ220	razna
5. Čajnici, džezve i sl.	P5	181.000	15.083	6,64	do Φ200	razna
6. Posude i lonci – razni	P6	297.000	24.750	10,90	do Φ400	razna
7. Ostalo posuđe i proizvodi	P7	453.000	37.750	16,61	razne	razna
	Ukupno:	2.726.000	227.166	100,00		

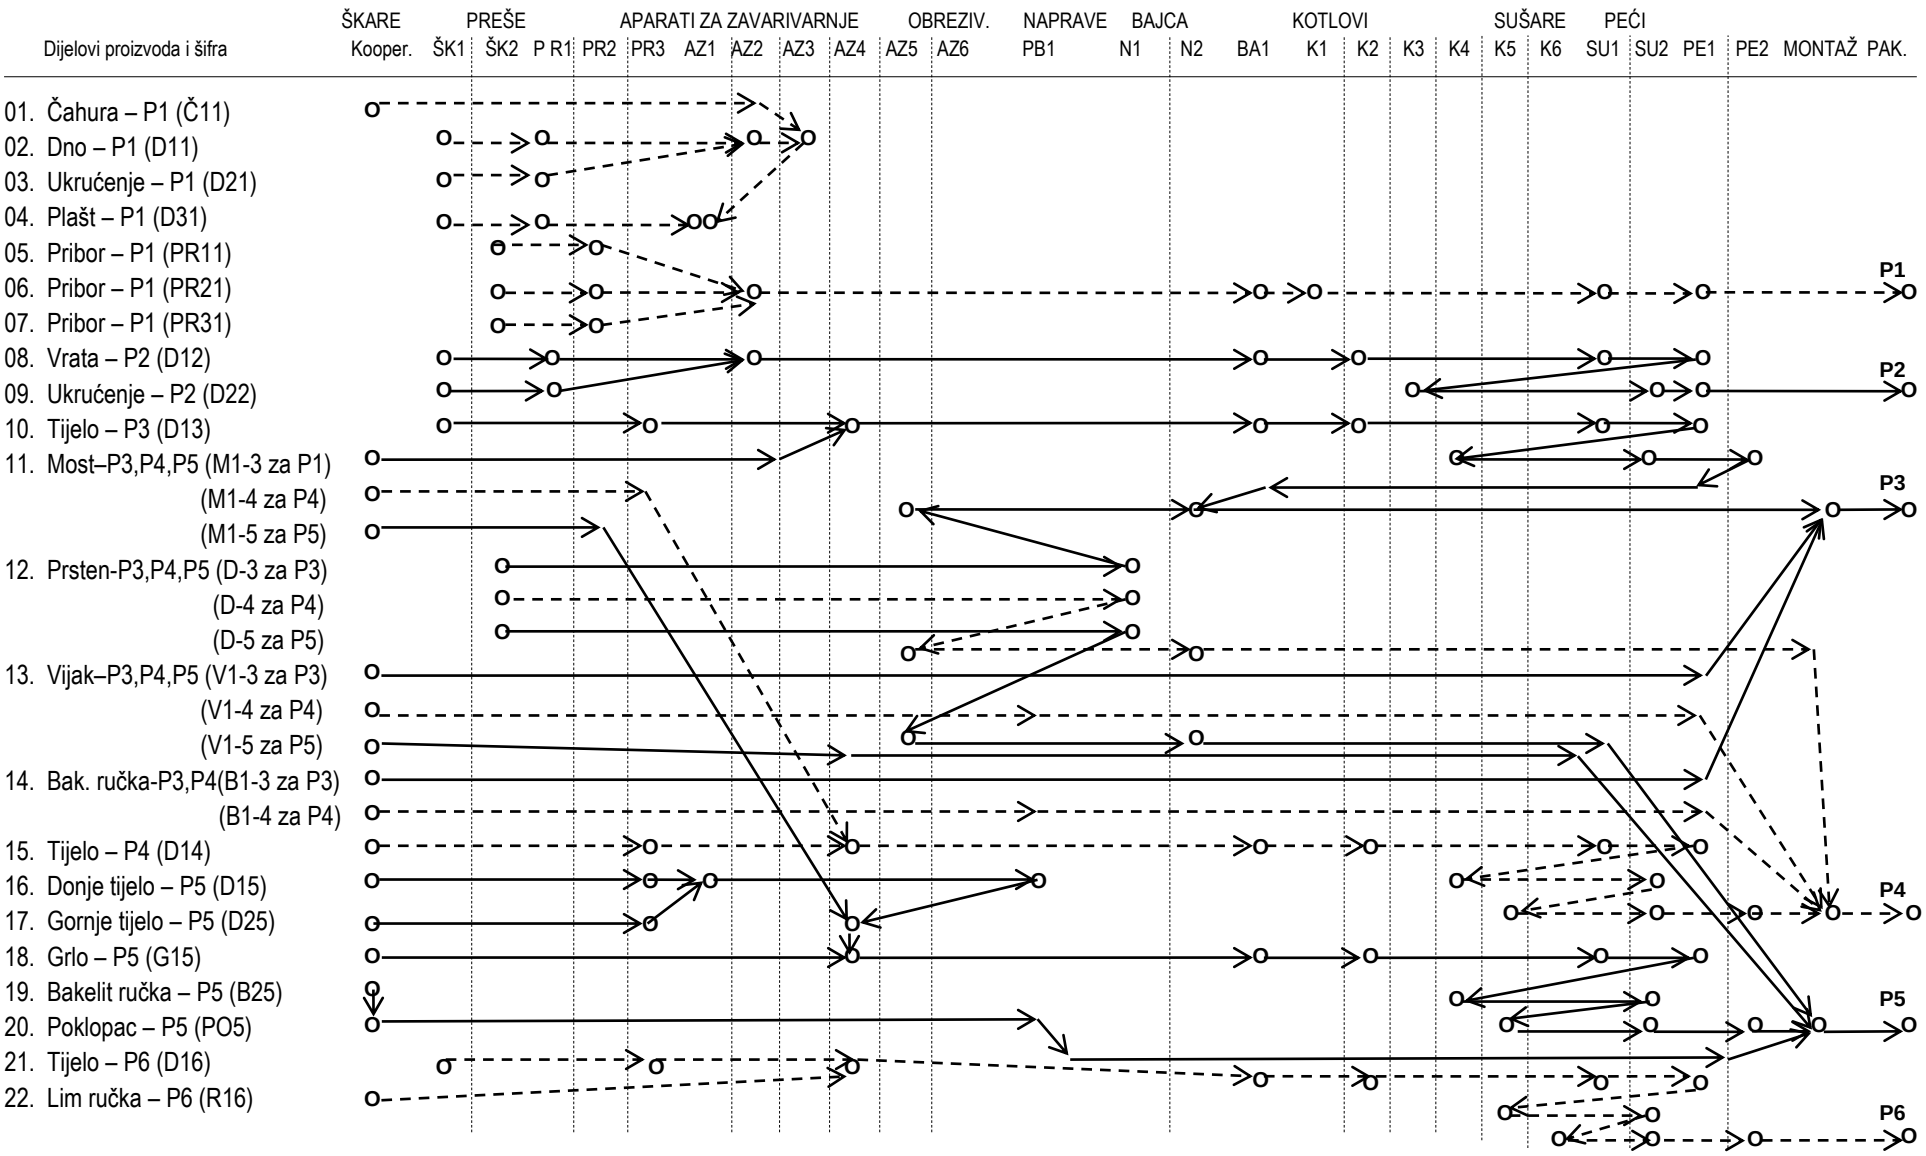

Slika 9. *Shematski prikaz toka proizvodnje grupa proizvoda u proizvodnji posuđa*

U Prilogu 9.1-1. je dat pregled strojeva, uređaja i zaposlenih po vrstama i broju s pripadajućim pregledom njihovih zastoja te vjerojatnostima trajanja razreda dužina zastoja. U obzir su uzeti samo oni zastoji strojeva, opreme i radnika koji su se odražavali na smanjenje realizacije proizvodnje jer je dio zastoja kod proizvodnje dijela proizvoda bilo moguće nadomjestiti realizacijom na drugim radnim mjestima, tj. strojevima.

Tablica u Prilogu 9.1-2. prikazuje pregled normativa i prosječnog mjesečnog utroška materijala i dijelova po grupama proizvoda za prosječnu mjesečnu realizaciju proizvodnje prema podacima iz tablice 1. Jedinični normativ utroška materijala dat je uprosječeno za sve proizvode jedne grupe točnim izračunavanjem prosjeka s obzirom na pojedinačne normative i učešće količina proizvoda u promatranoj grupi. Pojednostavljenja su rađena na način da se sličan materijal uključio u najbližu od navedenih grupa, najzastupljeniju u korišenju.

Za sve proizvode postoji uredno razrađena konstrukciona i tehnološka dokumentacija s normativima vremena i materijala za proizvodnju, uz koje se nalaze i krojne skice za dobivanje rondela za izvlačenje utvrđene optimizacijom iz ploča lima 2000 x 1000 m

Ocjenjujući proces proizvodnje, može se konstatirati sljedeće:

1. Konstrukciona i tehnološka definiranost proizvoda i proizvodnje zadovoljava
2. Proizvodni proces se odvija tehnologično, bez uskih grla kod instaliranih kapaciteta
3. Pouzdanost i kvalitet strojeva i opreme uglavnom zadovoljava, osim opreme za elektrootporno zavarivanje
4. Pouzdanost radnika ne zadovoljava zbog velikog broja izostanaka i time uzrokovanih zastoja u proizvodnji te visokog postotka škarta proizvoda
5. Korišteni repromaterijali uglavnom zadovoljavaju i većinom se racionalno troše, osim kod emajliranja zbog puno ručnog rada.

4.2. Stanje u plasmanu proizvoda

Snimanjem su obuhvaćeni glavni podaci i dokumenti prodaje za period od pet godina i kojima se obuhvaća stanje plasmana svih proizvoda te je izvršena procjena dijela nedostajućih podataka nakon čega su prikupljeni podaci sortirani i sistematizirani po grupama proizvoda i pri tome su prikazani sljedeći podaci:

a. Prosječna prodaja grupe proizvoda po mjesecima u godini
b. Prosječna mjesečna isporuka stalnih i dopunskih narudžbi kupcima
c. Odstupanja veličina redovitih isporuka kupcima
d. Broj i rokovi isporuka po kupcima
e. Broj i vjerojatnost pojave količine, rokova isporuke i termina naručivanja izvranrednih narudžbi

Također je opisan način plasmana proizvoda i zakonitosti tog procesa što je obuhvatilo:

- učestalost obrade tržišta plasmana proizvoda
- pojave zastoja u radu zaposlenih na plasmanu proizvoda
- pojave reklamacije proizvoda i njihove veličine
- kašnjenja u otpremi proizvoda

Narudžbe prodaje, odnosno isporuke kupcima svrstane su u tri kategorije:

1. stalne, godišnje ugovorne narudžbe redovnih kupaca
2. izvanredne, dopunske narudžbe redovnih kupaca
3. dodatne narudžbe povremenih i ostalih kupaca

U snimci stanja plasmana proizvoda nije obrađena 7. grupa proizvoda iz tablice 1. na stranici 54. zbog svoje raznolikosti i složenosti, a nije od značajnog utjecaja na istraživanje. Na taj je način snimanjem obuhvaćeno oko 80% plasmana što je dovoljno pouzdano za kvalitetnu konstataciju stanja i daljnje istraživanje. Također je opisano istraživanje tržišta, ugovaranje i realizacija procesa prodaje, a na kraju je dana rekapitulacija snimke procesa plasmana uz komentar i ocjenu postojećeg stanja.

Grupa proizvoda P1 predstavlja proizvode iz stalne i po obujmu značajne kooperacije za tri poznata kupca s podacima i obilježjima plasmana navedenim u Prilogu 9.1-3.

Grupa proizvoda P2 predstavlja grupu stalnih usluga i povremene kooperacije pa su zbog većeg broja i složenosti te grupe proizvoda i kupaca uzeta u razmatranje dva najveća kupca za koje se isporuke po prosječnim redovnim mjesečnim narudžbama i pripadajućim količinama obavljaju kako je to prikazano u Prilogu 9.1-4.

Grupa proizvoda P3 predstavlja grupu manjih posuda i lonaca do promjera Φ220 mm i rade se za veći broj kupaca pri čemu svaki kupac pokriva i predstavlja jednu regiju za koju je zadužen jedan trgovački putnik, a podaci za tu grupu plasman prikazani su u Prilogu 9.1-5.

Grupa proizvoda P4 predstavlja grupu većih posuda i lonaca promjera većeg od Φ220 mm, a proizvodi se također za veću grupu kupaca pri čemu svaki kupac pokriva i predstavlja jednu regiju na kojoj djeluje trgovački putnik i čiji su podaci i obilježja dati u Prilogu 9.1-6.

Čajnici, džezve i slični proizvodi do promjera Φ220 mm predstavljaju grupu proizvoda P5 koji se također rade i isporučuju za veći broj kupaca kao prethodne dvije grupe proizvoda, a podaci za tu grupu plasman vide su u Prilogu 9.1-7.

Posude, lonci i drugi slični proizvodi jeftinije izvedbe i dizajna čine grupu proizvoda P6 koji se isporučuju većem broju kupaca na način opisan za prethodne grupe proizvoda, a prikaz i obilježja njihovog plasman naveden je u Prilogu 9.1-8.

Promatrajući ukupan plasman svih grupa proizvoda kao prvo se utvrđuje da se oko 60% plasman obavlja za poznatog kupca, no zbog nedovoljne obrade tržišta rijetko i nepravovremeno se dobivaju informacije o točnim veličinama redovnih i dodatnih narudžbi te njihovim rokovima isporuka. Može se reći da se stvarno samo 41% plasmana radi za potpuno poznatog kupca i stoga se za proizvodnju daju planovi i nalozi za proizvodnju za zalihe.

Obrada tržišta obavlja se 1-2 puta tjedno u smislu nuđenja proizvoda, bez posebnog plana tog potprocesa plasmana proizvoda, a glavna podloga za utvrđivanje potreba tržišta su podaci o plasmanu proteklih godina gdje se uočava naglašeni sezonski karakter potražnje i plasmana proizvoda.

Otprema robe redovnim kupcima se obavlja obično kroz dvije isporuke tijekom mjeseca, a ostalima jedan puta mjesečno, i zapravo se radi o zbirnim isporukama za neku regiju u nekom dijelu mjeseca. Odstupanja količina u isporukama u odnosu na okvirne narudžbe, a koje se konačno i posebno potvrđuju od kupca za svaki mjesec, kreću se u rasponu -20% do +20% od veličine najavljene narudžbe. Dopunskih narudžbi redovnih kupaca ima do 10 u mjesecu, a kreću se prosječno u veličini 5-25% od redovnih mjesečnih narudžbi, pri čemu se traže rokovi isporuke 2-10 radnih dana od dana naručivanja.

Sve to potvrđuje ocjenu o nedovoljnoj obradi i poznavanju tržišta što se rješava većom proizvodnjom za zalihe.

4.3. Stanje u nabavi repromaterijala

Konstatacija stanja u procesu nabave repromaterijala izvedena je snimanjem dokumenata nabave za razdoblje od pet godina i intervjuima sa zaposlenima gdje su prikupljeni i dijelom procijenjeni podaci sortirani i sistematizirani u sljedećim grupama:

a. potrošnja repromaterijala po proizvodima

b. zalihe, količine za nabavu i rokovi dobave

c. zastoji i poremećaji u snabdijevanju

d. način rada

U posljednjoj grupi podataka snimljena je obrada tržišta nabave i aktivnosti u procesu nabave repromaterijala, pri čemu su utvrđeni poremećaji u radu izvršilaca poslova te reklamacije dobavljačima. S obzirom na nekompletnost dokumentacije i nemogućnost preciznijeg utvrđivanja podataka, dio podataka je dobiven u razgovoru s izvršiocima poslova nabave kao njihova iskustvena procjena.

U Prilogu 9.1-2. prikazan je pregled normativa i prosječnog mjesečnog utroška materijala i dijelova po grupama proizvoda s količinama u bruto iznosu. Zalihe repromaterijala su približno na nivou jednomjesečne potrošnje, a dijelom se mijenaju sezonski, prateći dinamiku plasmana proizvoda.

U Prilogu 9.1-9. je prikazan pregled zaliha i dobavljača repromaterijala gdje su maksimalne i signalne zalihe te količine repromaterijala u zaokruženim veličinama jer se od njih često odstupa pošto nema razrađenog i kontinuiranog upravljanja zalihama. Osim toga, nedovoljno kvalitetno operativno planiranje i praćenje te slabo istraživanje tržišta uzrokuju češće promjene i odstupanja od navedenih veličina zaliha, ali će se za ovo istraživanje moći zadovoljavajuće koristiti podaci iz Priloga 9.1-9. Tu su također navedeni i posebnim oznakama obilježeni mogući dobavljači repromaterijala, a uvršteni su najčešći dobavljači i oni koji isporučuju više vrsta potrebnih reprometrijala. Uz to su date i oznake zakonitosti mogućih količina za nabavu dobivene iz razgovora sa zaposlenima, svaka pridružena svakom od navedenih, raspoloživih dobavljač, posebno prikazane u Prilogu 9.1-10.

Svaka grupa mogućih količina nabave repromaterijala prikazana je srednjom vrijednošću raspona stvarno mogućih količina za isporuku u traženom momentu, a vjerojatnosti pojave su iskustvenom procjenom utvrđene kao prosječne za sve varijante.

Mogući rokovi dobave repromaterijala od dana naručivanja kreću se kod većih dobavljača u rasponu od 6-25 radnih dana, a kao vjerojatnost pojave mogućih dana isporuke uzete su jednake vjerojatnosti za svaki rok u okviru navedenog raspona.

U dopremi repromaterijala kasni se u 18% slučajeva a vrijeme kašnjenja iznosi do 10 radnih dana, odnosno do 2 tjedna. Pri tome se reklamacije pojavljuju u 11% slučajeva, a reklamirane količine iznose 5-30% od naručenih količina i rješavaju se u roku od 5-15 radnih dana.

4.4. Stanje u operativnom planiranju i praćenju proizvodnje

4.4.1. Terminiranje, priprema, realizacija i praćenje procesa

Za ovaj dio procesa operativnog planiranja i praćenja karakteristične su tri grupe aktivnosti:

a. polazno terminiranje i priprema realizacije
b. praćenje realizacije i njeno usklađivanje
c. evidentiranje podataka i informiranje o realizaciji

Ove grupe aktivnosti se izvode u okviru vremenskog perioda od tjedan dana, najčešće 1-2 puta tjedno na početku tjedna i za planiranje i za praćenje, a rutinska aktivnost praćenja i evidencije realizacije proizvodnje i drugih uključenih aktivnosti obavlja se svakodnevno, bez značajnog utroška vremena za njihovu analizu.

U snimljenom procesu rada ostvaruje se realizacija proizvodnje u odnosu na postavljene planove prosječno $\bar{x}_{rp}$ =92% u rasponima $(\bar{x}_{rp})_{min.}$=82% do $(\bar{x}_{rp})_{max.}$=128%, dok se odstupanja izvršenja planova po grupama proizvoda kreću u granicama +52% do -52% od navedenog prosječnog izvršenja po količinama.

Podudarnost potrebnih i lansiranih, odnosno realiziranih radnih naloga iznosi 72%, što znači da se zbog lošeg planiranja i poremećaja u radu značajno odstupa u realizaciji proizvodnje u odnosu na postavljene planove.

Zalihe proizvoda iznose 102% od isporučenih količina i variraju u granicama 58-147% od prosječnih zaliha, dok zalihe sirovina iznose 107% od utrošenih količina, a kreću se u granicama 54-133% od prosječnih zaliha.

U ostalim procesima rada izvršava se u roku i potrebnoj kvaliteti oko 70% poslova, kašnjenje je prisutno u cca 30% slučajeva, a vremena kašnjenja iznose prosječno 20% od planiranog kalendarskog vremena za realizaciju.

4.4.2. Mjesečno planiranje i praćenje

Mjesečno planiranje i praćenje procesa analizirano je po tri karakteristične grupe aktivnosti:

a. izrada mjesečnih planova

b. izrada mjesečnih obračuna i izvještaja

c. izmjene i dopune mjesečnog plana

U promatranom objektu istraživanja, proizvodnji posuđa, kao nisko organiziranom sustavu, faze mjesečnog planiranja i praćenja izvode se bez unaprijed definirane tehnologije rada i potrebnih, definiranih algoritama. To je uglavnom prepušteno samim izvršiocima, uz manje određene upute rukovodioca, koji potrebne podatke prikupljaju kampanjski uz usmene konzultacije sa proizvodnjom, prodajom i nabavom, pojedinačno ili na operativnim sastancima.

Kao druga podloga za izradu planova uzima se procjena stanja zaliha i tekuće realizacije proizvodnje, uz korištenje malog broja izvora informacija.

Na izradi mjesečnog plana radi se 7-10 dana krajem prethodnog i početkom sljedećeg mjeseca, pri čemu se s izradom mjesečnih planova kasni u skoro 50% slučajeva. Mjesečni planovi ne sadrže planove aktivnosti koje treba poduzeti da bi se planirani sadržaji u što većem obujmu, na vrijeme i kvalitetno izvršili. Prikupljanje podataka za izradu mjesečnog obračuna i izvještaja izvodi se 5-7 dana nakon završetka mjeseca zbog nepravovremenog ažuriranja podataka potrebnih za izradu obračuna i izvještaja.

Mjesečni obračun i izvještaj su zbir pojedinačnih obračuna i izvještaja, bez povezivanja obilježja i njihove analize, a naglasak je na financijskom aspektu izvještaja.

4.4.3. Kvartalno planiranje i praćenje

Polazni, prvi kvartalni plan obično se izvodi kao dio jedinstvenog godišnjeg plana i radi se zajedno s njim, dok se planovi za ostale kvartale rade ili kao suma tri gruba sljedeća mjesečna plana ili izvodom za sljedeći kvartal iz godišnjeg plana.

Ovdje vrijede slične ocjene kao za izradu mjesečnih planova, izvještaja i obračuna, čak jedan stupanj niže, osim onih dijelova koji se podnose upravi poduzeća zbog formalne rasprave i usvajanja.

4.4.4. Godišnje planiranje i praćenje

Praktično imamo dva gotovo nezavisna dijela i različite grupe aktivnosti za izradu godišnjeg plana s jedne strane te godišnjeg obračuna i izvješća s druge strane, pri čemu se godišnjem obračunu poklanja najveća pažnja. Izrada godišnjeg plana obično započinje u XII mjesecu tekuće godine i traje čak do kraja II mjeseca planske godine, a sastoji se od planova prodaje, nabave, razvoja, kadrova, investicija i troškova, zaokruženo s ukupnim financijskim planom, baziranim na djelomičnim podacima, procjenama, željama i uputama rukovodstva poduzeća.

Godišnji plan je najčešće zbir pojedinih planova po sadržajima rada i organizacijskim procesima gdje su obično osnovni sadržaji pojedinih planova relativno zadovoljavajuće definirani, a dijelom i propisani dok je postupak njihove izrade vrlo grubo definiran i obvezno nedostaje plan mjera i aktivnosti za što efikasnije izvršenje godišnjeg plana.

Prilikom konačne razrade godišnjih planova rijetko se primjenjuju metode i tehnike optimizacije i rijetko se provjeravaju mogući putevi ostvarenja većih poslovnih efekata. U slučaju značajnijeg odstupanja od polaznih osnova godišnjeg plana ili nekih njegovih dijelova obavljaju se manje ili veće korekcije ili usklade tih dijelova plana. Predloženi godišnji plan raspravlja se i verificira od strane Uprave poduzeća.

Godišnji obračun i izvještaj poslovanja izrađuje se u razdoblju od I. do III. mjeseca tekuće godine za prethodnu na način i u formi propisanim Zakonom gdje dominira financijski prikaz poslovanja u prethodnoj godini. Povremeno se radi detaljno izvješće o poslovanju za proteklu godinu, a izvješće je uglavnom komentar financijskih i glavnih materijalnih podataka i pokazatelja poslovanja. Godišnji obračun i izvještaj se pregledava, raspravlja i usvaja u propisanoj proceduri od strane Uprave poduzeća.

4.4.5. Analitički prikaz stanja planiranja i praćenja

Analitički prikaz stanja planiranja i praćenja napravljen je po četiri karakteristične faze - pripremne aktivnosti i veze s povezanim procesima rada; izrada planova i izvještaja; praćenje realizacije i usklađivanje planova i realizacije; vođenje, kontrola i odlučivanje.

U okviru pripremnih aktivnosti planiranja i praćenja u okviru promatranog objekta istraživanja 1-2 puta tjedno se obavlja obrada pet stalnih kupaca u kooperantskom odnosu te 45 grupa veletrgovaca u okviru 11 regija prodaje. Od ukupnog asortimana od 300 proizvoda prodaje se oko 240, a plasman se u 40% slučajeva vrši za potpuno poznatog i još u 20% slučajeva za djelomično poznatog kupca.

Redovne narudžbe odstupaju zbog naknadnih promjena zahtjeva kupaca po količinama u granicama od -20% do +20%, a mjesečno se pojavi do 12 dopunskih narudžbi čije su količine 5-25% od redovnih narudžbi.

Izostanci zaposlenih na poslovima prodaje i otpreme pojavljuju se i traju prema zakonu distribucije prikazane na slici 10.

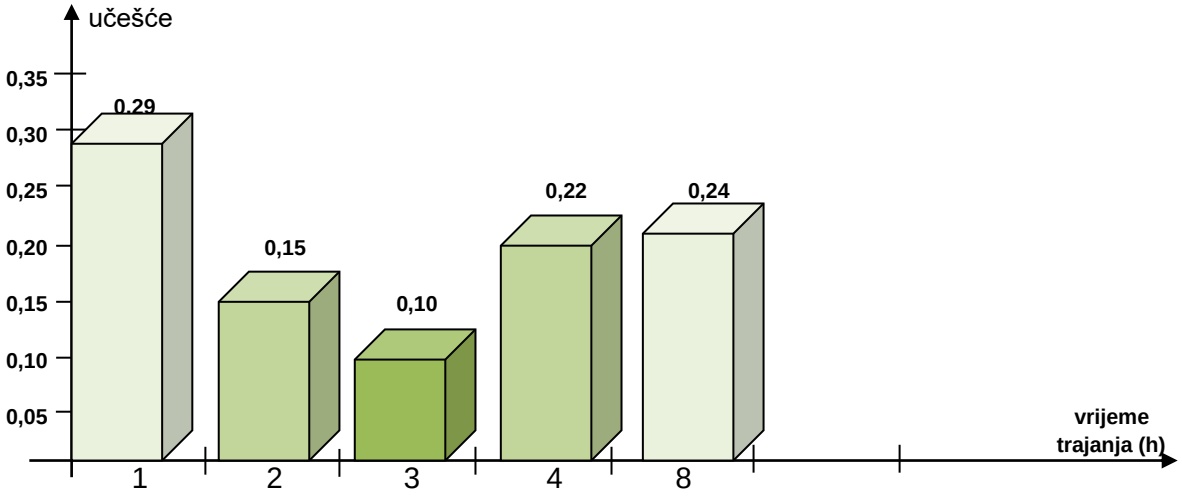

Slika 10. *Zakon distribucije izostanaka izvršioca u prodaji i otpremi*

Istraživanje tržišta nabave nije definirano ni organizirano pa se promatrani sustav oslanja na manji broj izvora snabdijevanja gdje se 20 glavnih repromaterijala nabavlja od samo 26 dobavljača, a pouzdanost snabdjevanja se osigurava ranijim narudžbama i većim zalihama repromaterijala. U dopremi repromaterijala kasni se u 18% slučajeva uz vrijeme kašnjenja do 10 radnih dana, a pojavljuje se 11% reklamacija pri kojima se reklamira 5-30% od naručenih količina.

Obzirom na relativno stabilan sezonski karakter prodaje te proizvodnju većim dijelom za zalihe, odnos planiranih, proizvedenih i prodanih količina iznosi kako slijedi:

1. odnos godišnje planiranih i prodanih količina – srednja vrijednost x_1= 0,92 uz standardnu devijaciju od σ_{x_1}= 0,025,
2. odnos mjesečno planiranih i prodanih količina - srednja vrijednost x_2= 1,04 uz standardnu devijaciju σ_{x_2}= 0,06
3. odnos mjesečno proizvedenih i prodanih količina – srednja vrijednost x_3= 1,01 uz standardnu devijaciju σ_{x_3}= 0,06

No, zato su značajna odstupanja po pojedinim grupama proizvoda gdje se odstupanja planiranih i realiziranih količina pojedinačno kreću u rasponu od -52 do -52%, čemu je glavni uzrok slabo i neodgovarajuće prikupljanje informacija na tržištu.

Aktivnosti praćenja i usklađivanja realizacije planova i sama proizvodnja u promatranom objektu istraživanja minimalna su i izvode se rutinski gdje se uglavnom vodi računa o kvanitativnim parametrima. Intenzitet prikupljanja i obrade informacija o realizaciji nije dovoljan i vrši se 1-3 puta tjedno uz kašnjenje u obradi i povratu do pet dana.

Reklamacije na otpremljene količine javljaju se u oko 15% isporuka pri čemu se reklamira 5-15% isporučenih količina. Kašnjenja u isporukama pojavljuju se u oko 20% slučajeva, a iznose prosječno x_z=3,14 radnih dana, u rasponu 1-5 radnih dana.

Odnos između prosječnih mjesečnih zaliha i utrošenih mjesečnih količina repromaterijala iznosi Os=1,07, a kod proizvoda taj omjer iznosi Op=1,02

Učestalost pojave zastoja kod opreme po pojedinim fazama proizvodnje je:

a. proizvodnja dijelova 3,07 +/- 1,56 dana (49 +/- 25 radnih sati)
b. proizvodnja poluproizvoda 2,56 +/- 1,54 dana (41 +/- 25 radnih sati)
c. proizvodnja gotovih proizvoda 4,62 +/- 2,11 dana (74 +/- 34 radnih sati)

Vođenje, kontrola i odlučivanje u aktivnostima planiranja i praćenja nije tehnološki razrađeno ni povezano s aktivnostima praćenja i usklađivanja realizacije. Dominira hijerarhijski rukovodni princip u odnosu na tehnologiju-način rada što samo po sebi često izaziva poremećaje. Odlučivanje se obavlja prvenstveno s apekta kvantitete (količine, sati rada, financijski prihodi i troškovi), bez dovoljno potrebne analitike za donošenje cjelovitih odluka. Kontrola realizacije je vrlo površna i često se na račun kvalitete i pravovremenosti djelovanja forsiraju prethodno navedeni parametri.

Zakoni distribucije vremena trajanja zastoja opreme po pojedinim fazama proizvodnje te izvršilaca u proizvodnji prikazani su na slikama 11., 12., 13. i 14.

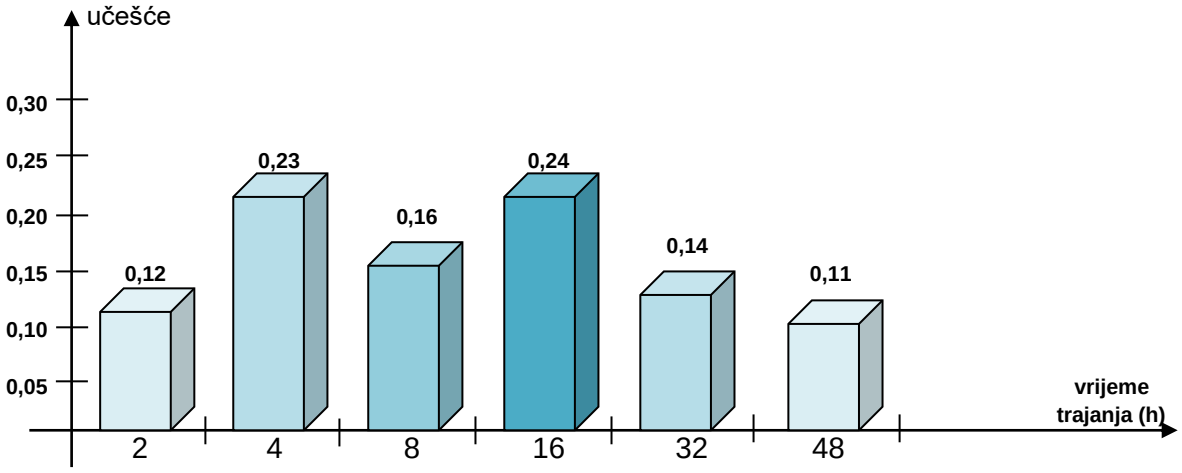

Slika 11. *Zakon distribucije vremena trajanja zastoja opreme u proizvodnji dijelova*

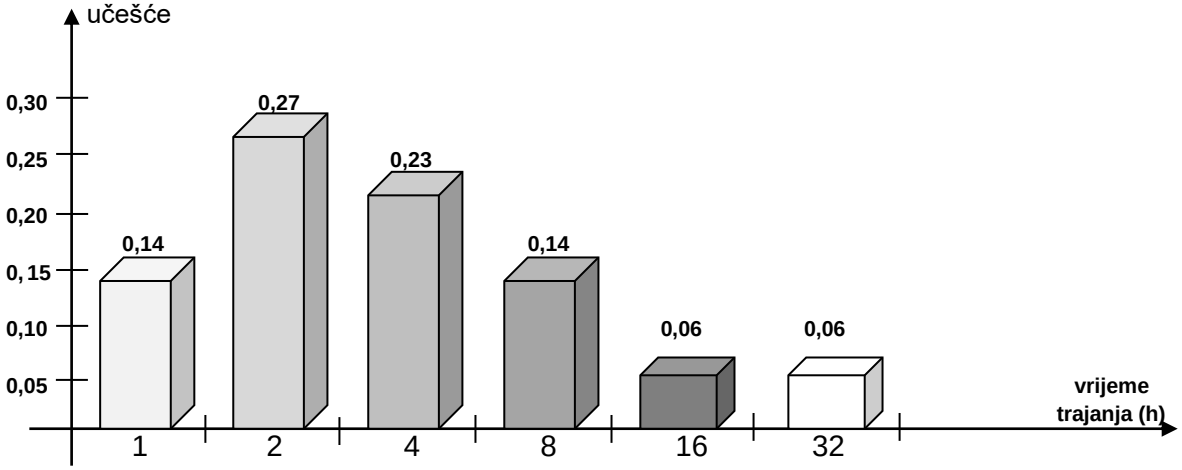

Slika 12. *Zakon distribucije vremena trajanja zastoja opreme u proizvodnji poluproizvoda*

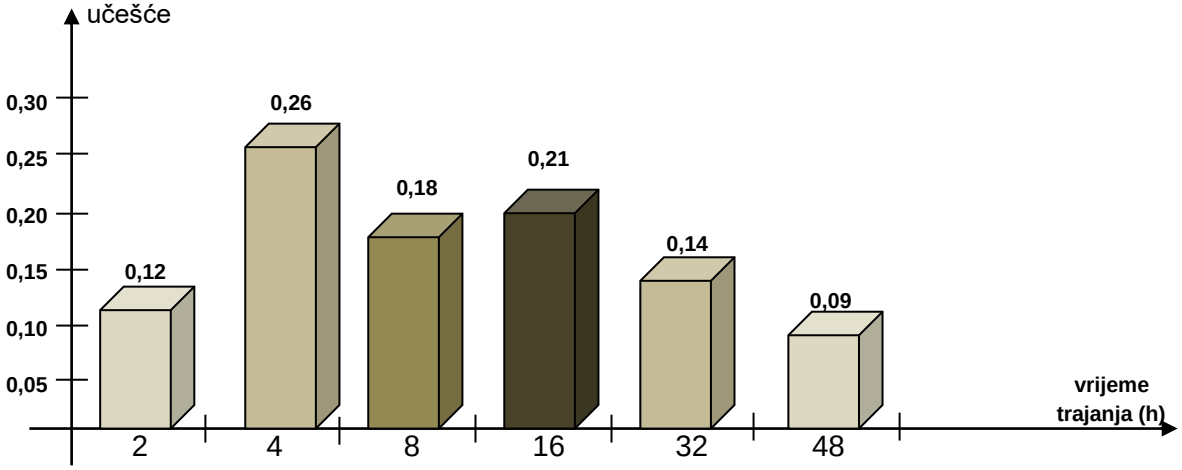

Slika 13. *Zakon distribucije vremena trajanja zastoja opreme u proizvodnji proizvoda*

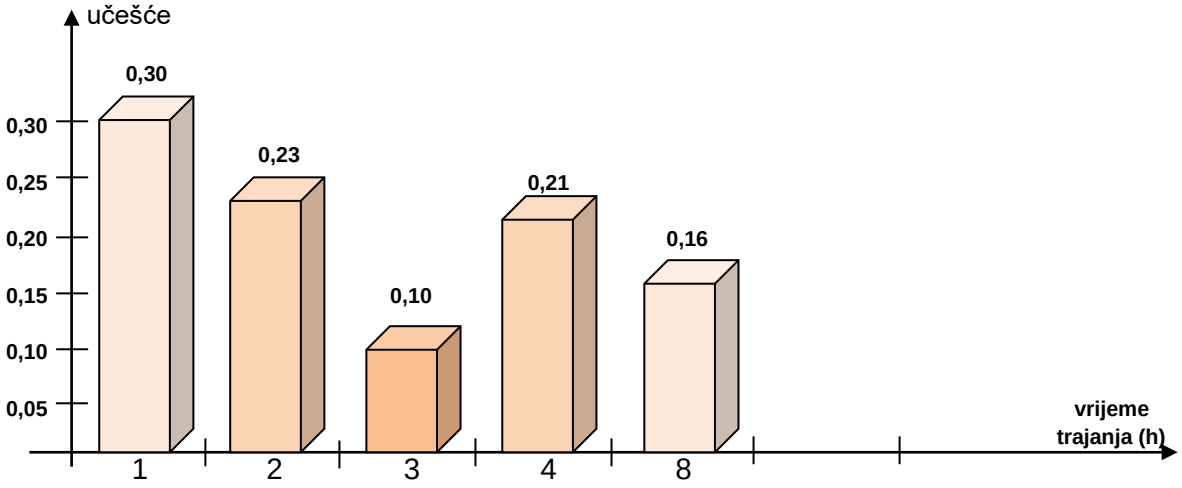

Slika 14. *Zakon distribucije vremena trajanja izostanaka izvršilaca u proizvodnji*

4.5. Ocjena postojećeg stanja

Ocjena postojećeg stanja daje se po odabranim kriterijima i mjerilima za operativno planiranje i praćenje u odabranom objektu istraživanja, a pregled vrijednosti obilježja i ocjena dat je u tablici 2. Sve vrijednosti u tablici 2. računate su prema izrazima od (1) do (17) navedenim u poglavlju 3.2., a prema rezultatima dobivenim snimanjem stanja.

Prema prvom kriteriju ocjenjivanja $\boldsymbol{U_1}$ - osjetljivost planiranja i praćenja, promatrani objekt istraživanja karakterizira po izrazu (1) nisko odstupanje varijacije S_V = (1 - $\sigma_{\bar{x}}/\bar{x}$) i visok stupanj točnosti S_T = (1 - $\Delta\bar{x}$).

Naime, za prosječni odnos godišnje planiranih i prodanih količina svih proizvoda od $\bar{x}_1$ =0,92, odnos mjesečno planiranih i prodanih količina od $\bar{x}_2$ = 1,04 i odnos proizvedenih i prodanih količina od $\bar{x}_3$ = 1,01 dobiva se prosječno $\bar{x}$= 0,99 pa je stupanj točnosti S_T = 0,99 vrlo visok. No, zato su značajna odstupanja navedenih odnosa po grupama proizvoda što rezultira standardnom devijacijom od $\sigma_{\bar{x}}$= 0,191 pa je odstupanje varijacije S_V= 0,809 relativno nisko te iz svega proizlazi niža osjetljivost planiranja $\boldsymbol{U_1}$= 0,798.

Zadovoljenost rokova kod promatranog objekta istraživanja niža je od one koja bi se smatrala prihvatljivom, kako zbog nižeg učešća zadovoljenih rokova U_{zr}=(R-R_z)/R tako i zbog nivoa kašnjenja N_k= 1 –$\bar{x}_z$ /$\bar{x}_{DI}$ izvedenih iz izraza (6).

Kašnjenje isporuka je zabilježeno u 14% slučajeva uz standardnu devijaciju od 2,72% pa je U_{zr}= 0,860, a sa prosječnim kašnjenjem od $\bar{x}_z$ = 2,14 dana i pripadajući $\sigma_{\bar{x}}$= 0,26 dana prema postavljenim rokovima isporuke od prosječno $\bar{x}_{DI}$= 25 dana, nivo kašnjenja iznosi N_k=0,914 pa je zadovoljenost rokova $\boldsymbol{U_2}$=0,787.

Snimanjem stanja zaliha proizvoda u odnosu na isporučene mjesečne količine utvrđen je pokazatelj O_p=1,020, a pokazatelj odnosa prosječnog stanja zaliha u odnosu na utrošene repromaterijale iznosi O_s=1,070 pa je efikasnost upravljanja zalihama $\boldsymbol{U_3}$= 0,957, odnosno, vrlo je loša.

Tablica 2. *Pregled vrijednosti obilježja i ocjena za operativno planiranje i praćenje u objektu istraživanja*

OBILJEŽJA I KRITERIJI	Oznaka	**Vrijednost**
01. Srednja vrijednost omjera godišnjih i mjesečnih planova te realizacije proizvodnje u odnosu na izvršeni plasman	$\bar{x}$	**0,990**
02. Standardna devijacija aritmetičke sredine omjera planova i realizacije proizvodnje u odnosu na izvršeni plasman	$\sigma_{\bar{x}}$	**0,191**
03. Ukupni godišnji broj postavljenih rokova isporuka	R	**1.322**
04. Godišnji broj nepoštivanih rokova isporuke, s kašnjenjem	R_z	**185**
05. Prosječni broj dana tražen za isporuke	$\bar{x}_{DI}$	**25**
06. Prosječan broj dana kašnjenja u isporukama	$\bar{x}_z$	**2,14**
07. Prosječan odnos stanja mjesečnih zaliha i mjesečno isporučenih količina proizvoda	O_p	**1,02**
08. Prosječan odnos stanja mjesečnih zaliha i mjesečno utrošenih količina repromaterijala	O_s	**1,07**
09. Osjetljivost planiranja i praćenja $\boldsymbol{U_1} = \left(1 - \frac{\sigma_{\bar{x}}}{\bar{x}}\right) \cdot (1 - \Delta\bar{x})$	$\boldsymbol{U_1}$	**0,798**
10. Zadovoljenost rokova $\boldsymbol{U_2} = ((R-R_z)/R) \cdot (1 - \bar{x}_z / \bar{x}_{DI})$	$\boldsymbol{U_2}$	**0,787**
11. Efikasnost upravljanja zalihama $\boldsymbol{U_3} = 1 / (1/2 \cdot (O_p + O_s))$	$\boldsymbol{U_3}$	**0,957**
12. Uspješnost planiranja i praćenja $U = \boldsymbol{U_1} \times \boldsymbol{U_2} \times \boldsymbol{U_3}$	U	**0,601**

4.6. Utvrđivanje utjecajnih faktora

U ovom prvom proučavanju stanja pokušati će se procjenama prema rezultatima snimanja stanja utvrditi utjecajni faktori na dobivene rezultate, a stvarno, kvantificirano djelovanje odabranih važnih utjecajnih faktora utvrditi će se istraživanjem na odabranom modelu putem oponašanja.

Kod analize pokazatelja po prvom kriteriju $\boldsymbol{U_1}$ – osjetljivost planiranja možemo zaključiti da do pada tog pokazatelja dolazi kod sustava s većim asortimanom proizvoda, složenijim proizvodima i proizvodnjom-realizacijom proizvoda i usluga. Složenost proizvoda i proizvodnje obično traži duže cikluse realizacije pa zbog toga treba imati i duže vremenske periode koji se obuhvaćaju odgovarajućim planovima na načina da osnovni plan nije mjesečni plan već kvartalni ili čak polugodišnji. Vjerojatnost promjena i poremećaja veća je u dužem vremenskom periodu planiranja a time se smanjuje osjetljivost planiranja proizvodnje.

Za ovdje promatrani proizvodni sistema s asortimanom od cca 250 proizvoda koji se rijetko mijenjanju i koji se sastoje od 2-10 pozicija i proizvodnjom od 12 grupa tehnoloških operacija možemo reći da je sustav s manjim stupnjem složenosti pa je njihov utjecaj na osjetljivost planiranja mali.

Također je utvđen mali intenzitet prikupljanja potrebnih ulaznih informacija pa možemo reći da se njihovim intenziviranjem može značajno povećati osjetljivost planiranja i praćenja te se može reći da bi intenzitet prikupljanja ulaznih informacija trebao biti utjecajan faktor.

Pouzdanost snabdijevanja s ulaznim repromaterijalima i ostalim potrebnim ulaznim elementima procesa proizvodnje pozitivno utječe na pouzdaniju realizaciju proizvodnje pa se samim time osigurava sigurnija i veća osjetljivost planiranja i praćenja.

Pouzdanost realizacije proizvodnje vezana je također i za pouzdanost rada strojeva i uređaja te efikasnost održavanja gdje manja učestalost zastoja i njihovo kraće trajanje osigurava veću realizaciju zacrtanih planova proizvodnje, a time i veću osjetljivost planiranja i praćenja.

Utvrđene zakonitosti pojave zastoja strojeva i opreme kod proizvodnje dijelova, poluproizvoda i gotovih proizvoda su relativno rjeđi i kraći zastoji pa je njihov utjecaj mali.

Ako je još pri tome, kao u ovom slučaju, manje korištenje instaliranih kapaciteta s većim mogućnostima korištenja raspoloživih zamjenskih kapaciteta, cca 30%, tada će zastoji strojeva i opreme manje utjecati na efikasnost proizvodnje, a samim time i na osjetljivost planiranja i praćenja.

Utvrđene učestalosti zastoja-izostanaka izvršilaca u proizvodnji te prodaji, otpremi i nabavi svakako utječe na osjetljivost planiranja i praćenja, a pogotovo ljudski faktor zbog nižeg nivoa kvalitete obavljenih poslova i kašnjenja u izvršenju poslova u 30% slučajeva.

To nam ujedno govori da faktor čovjek djeluje dvojako:

a. kao objekt-resurs u kvantitativnom smislu (radi-ne radi)
b. kao subjekt, upravljač i kreator poslova u kvalitativnom smislu

Zadovoljenost rokova $\boldsymbol{U_2}$ kao jedan od pokazatelja uspješnosti operativnog planiranja i praćenja osjetno je pod utjecajem ukupne pripreme i vođenja nekog procesa i njegove realizacije, a sve to je prvenstveno pod utjecajem faktora čovjek.

Učestalost i vrijeme trajanja zastoja čovjeka prema utvrđenim zakonitostima ima značajan utjecaj na pojave kašnjenja u isporukama koje se registriraju u 14% slučajeva, s prosječnim kašnjenjem od $\bar{x}_z$ = 2,14 dana i rasipanjem $\sigma_{\bar{x}}$= 0,26 dana gdje raspon kašnjenja iznosi 1-4 dana u odnosu na prosječno utvrđeni rok isporuke od $\bar{x}_{DI}$ =25 dana.

Svi ostali utjecajni faktori u većem dijelu utječu na zadovoljenost rokova indirektno, kao što se to npr. iskazuje kod djelovanja intenziteta prikupljanja ulaznih informacija, načina obrade i prijenosa podataka te načina planiranja. Ako se pri tome osigurava veća pouzdanost snabdjevanja s repromaterijalom te manja učestalost i vrijeme trajanja zastoja strojeva i opreme, može se očekivati dodatno povećanje zadovoljenosti rokova.

Veličina asortimana, složenost proizvoda i proizvodnje, kao i ostali utjecajni faktori navedeni kod ocjenjivanja osjetljivosti planiranja i praćenja, nemaju veći značaj na zadovoljenost rokova jer se djelovanje na njih radi tijekom planiranja i pripreme proizvodnje.

Efikasnost upravljanja zalihama $\boldsymbol{U_3}$ relativno je najlošiji pokazatelj uspješnosti operativnog planiranja i praćenja u promatranom sustavu. Najveći utjecaj na taj pokazatelj ima oblik plasmana proizvoda koji karakterizira veći dio isporuke proizvoda sa zaliha, odnosno 60% plasmana, a samo 40% je za unaprijed poznatog kupca s njegovim potpuno definiranim zahtjevima.

To potvrđuje i omjer mjesečnih zaliha i isporučenih količina gotovih proizvoda od O_p=1,02, što znači da je na zalihama jednomjesečna proizvodnja, kao i kod repromaterijala gdje je omjer zaliha i potrošnje O_s=1,07. Takvo stanje je uglavnom posljedica nepouzdanosti snabdijevanja i slabog poznavanja i istraživanja tržišta nabave, iako za to nema puno objektivnih razloga s obzirom na mali broj potrebnog repromaterijala.

Na temelju prethodnog proučavanja stanja mogu se potvrditi utjecajni faktori s procjenom jačine djelovanja u četiri stupnja, kvalitatitivno rangirani po jačini djelovanja kako slijedi:

1. VSSS – jako djelovanje
2. SSS – izraženo djelovanje
3. SS – značajno djelovanje
4. S – prisutno djelovanje

Kod utjecajnih faktora koji nemaju niti jedan od navedenih stupnjeva utjecaja, radi se o slabijem, zanemarivom ili neodređenom djelovanju.

Utjecajni faktori i njihovo djelovanje utvrđuju se kako slijedi:

01. Veličina asortimana proizvoda u proizvodnji tijekom godine . . . . . S
02. Složenost proizvoda i raznovrsnost njihovih pozicija . . . . . S
03. Složenost proizvodnje i raznovrsnost tehnologija . . . . . S
04. Oblik snabdijevanja s repromaterijalom, broj izvora i neposrednost snabdijevanja . S
05. Oblik plasmana proizvoda i poznavanje potreba kupaca . . . . . VSSS
06. Karakter potražnje proizvoda po kalendarskom vremenu i zakonitostima . . . .SS
07. Intenzitet prikupljanja ulaznih informacija potrebnih za planiranje i praćenje . . SSS
08. Način planiranja i praćenja i intenzitet usklađivanja potreba i planova. . . .VSSS
09. Osnovni planski period po vremenskom obuhvatu . . . . . -
10. Način donošenja odluka i pravovremenost odlučivanja . . . . . -
11. Način prijenosa i obrade podataka . . . . . -
12. Smještaj informacijskog podprocesa i povezanost s radnim podprocesom . . . -
13. Učestalost zastoja čovjeka – pouzdanost izvršilaca . . . . . SSS
14. Vrijeme trajanja zastoja čovjeka i njegova osposobljenost . . . . . SSS
15. Učestalost zastoja strojeva i opreme – pouzdanost strojeva i opreme . . . . . SS
16. Vrijeme trajanja zastoja strojeva i opreme – kvalitet održavanja . . . . . SS
17. Iskoristivost strojeva i opreme – raspoloživost kapaciteta. . . . . S

S obzirom da je tako velik broj utjecajnih faktora teško tretirati pri jednom ovakvom proučavanju, potrebno ih je svesti na prihvatljivu mjeru, a taj će postupak biti izveden diskusijom u opisu i temeljen na kvalitativnoj procjeni njihovog djelovanja, podobnosti za daljnje tretiranje i značaju kao mogućnosti našeg djelovanja na njihov utjecaj.

Putevi smanjivanja broja utjecajnih faktora za daljnje istraživanje izvršiti će se na jedan od sljedećih načina: a. izostavljanje utjecajnih faktora

b. kondenzacija utjecajnih faktora

Razlozi za izostavljanje utjecajnih faktora mogu biti njihov mali značaj na uspješnost operativnog planiranja i praćenja ili poteškoće kod njegovog tretiranja u daljnjem radu.

Kondenziranje utjecajnih faktora je bolji put smanjivanja broja utjecajnih faktora za daljnje istraživanje gdje se od dva ili više srodnih, a jednostavnih faktora, gradi jedan složeni. Na taj način se dolazi do efekta tako složenog faktora, a da njegovi članovi nisu izostavljeni pa ukoliko su interesantni, mogu se u nastavku istraživanja tretirati pojedinačno.

Iz daljnjeg tretiranja u istraživanju izostaviti će se faktori veličina asortimana proizvoda, složenost proizvoda, složenost proizvodnje i iskoristivost kapaciteta te će se isti držati konstantnim. Isto vrijedi za faktor karakter potražnje proizvoda, a osim toga utjecaj tog faktora dijelom će se pokriti faktorima intenzitet prikupljanja ulaznih informacija te način planiranja i praćenja.

Oblik snabdijevanja s repromaterijalom izostavlja se iz daljnjeg istraživanja zbog poteškoća kod njegovom tretiranju na višem nivou.

Zbog slabijeg dijelovanja te ostalih razloga za prethodno navedene faktore izostaviti će se iz daljnjeg istraživanja i faktori vremenski period planiranja, način donošenja odluka, način prijenosa i obrade podataka te smještaj informacijskog podprocesa.

Zbog sličnosti karaktera i jačine djelovanja kondenzirati će se faktori učestalost zastoja strojeva i opreme s faktorom vrijeme trajanja zastoja strojeva i opreme, kao i faktori učestalost zastoja čovjeka i vrijeme trajanja zastoja čovjeka.

Prema tome, u daljnjem istraživanju će se tretirati sljedeći utjecajni faktori:

A. INTENZITET PRIKUPLJANJA ULAZNIH INFORMACIJA
B. OBLIK PLASMANA PROIZVODA
C. NAČIN PLANIRANJA I PRAĆENJA PROIZVODNJE
D. UČESTALOST I VRIJEME TRAJANJA ZASTOJA STROJEVA
E. UČESTALOST I VRIJEME TRAJANJA ZASTOJA ČOVJEKA

Navedeni utjecajni faktori su odabrani između ostalog i zbog toga što im je kod promatranog objekta istraživanja jednostavno i na realan način moguće odrediti nivoe tretmana.

Veći broj faktora za daljnje tretiranje nije uzet iz razloga što je gotovo nemoguće interpretirati interakcije viših redova, naročito ne iznad petog reda.

4.7. Utjecajni faktori za istraživanje na modelu

Za istraživanje na modelu potrebno je izabrane glavne utjecajne faktore jasno definirati, opisati ih te odrediti njihov 1. i 2. nivo tretiranja u okviru faktorskog plana pokusa i ukupnog istraživanja modela prilagodljivog, kliznog planiranja i praćenja proizvodnje, opisanog u poglavlju 3.3. Taj model, kao 2. nivo utjecajnog faktora C-način planiranja i praćenja proizvodnje, treba ispitati u okviru faktorskog plana pokusa kako bi se uz njegov utjecaj vidjelo i njegovo interaktivno djelovanje s drugim utjecajnim faktorima u tretiranju.

1. Faktor A - intenzitet prikupljanja ulaznih informacija

Ovaj je utjecajni faktor definiran kao obuhvat i kontinuitet te postupak prikupljanja potrebnih ulaznih informacija za operativno planiranje i praćenje proizvodnje iz procesa plasmana proizvoda, nabave repromaterijala, proizvodnje te operativnog planiranja i praćenja.

Za kvalitetnu pripremu, izvođenje i praćenje bilo kojeg dijela promatranih procesa potrebne su iz okruženja i iz samog procesa određene ulazne informacije koje su ovdje sistematizirane po sljedećim grupama:

a. pojavljivanje potencijalnih kupaca s narudžbama
b. vrste i količine traženih proizvoda s rokovima isporuke
c. mogući izvori snabdijevanja s repromaterijalima
d. potrebne vrste i količine repromaterijala s rokovima dobave
e. vrste i veličine raspoloživih kapaciteta
f. stanje svih vrsta zaliha
g. plan proizvodnje i isporuka
h. stanje realizacije u proizvodnji
i. poremećaji i zastoji u proizvodnji
j. raspoloživost ljudskih resursa
k. poremećaji i zastoji u radu čovjeka-izvršilaca

Navedene grupe podataka dobivaju se obavljanjem odgovarajućih aktivnosti u obuhvaćenim procesima pa ovaj utjecajni faktor ima procesni karakter. Zbog složenosti tih poslova i nedostatka podloga za njihov funkcionalno-matematički prikaz, ovaj će se faktor tretirati kao "rad" ili "nerad" u sva četiri tretirana procesa u nekom vremenskom trenutku.

Nivoi tretiranja ovog faktora izraženi su brojem prikupljanja informacija potrebnih za operativno planiranje i praćenje svakog od četiri promatrana procesa u jednom tjednu, i to:

1. **nivo A1** – 2 prikupljanja informacija tjedno po dijelu procesa
2. **nivo A2** – 5 prikupljanja informacija tjedno po dijelu procesa

Za drugi nivo je uzeto 2,5 puta češće prikupljanje informacija jer nema niti jednog objektivnog razloga da se tako obavlja u promatranom objektu istraživanja i za to se ne traži nikakvo posebno osposobljavanje izvršilaca već samo veći red i odgovornost.

2. Faktor B - oblik plasmana proizvoda

Oblik plasmana proizvoda podrazumijeva način zadovoljavanja potreba kupaca otpremom sa zaliha gotovih proizvoda ili isporukama po naružbama poznatih kupaca, odnosno poznavanje kupca. Drugim riječima, možemo govoriti o većem ili manjem poznavanju tržišta i kupaca pa se, ovisno o tome, proizvodi mogu proizvoditi za zalihe, a otpremati po pojavi zahtjeva-narudžbi kupaca, ili se proizvodnja organizira po većem broju unaprijed poznatih zahtjeva-narudžbi kupaca a otprema se obavlja po gotovosti narudžbe.

Prema tome, oblik plasman proizvoda imati će dva nivoa tretiranja, kako slijedi:

1. **nivo B1** – plasman po primitku zahtjeva-narudže s otpremom sa zaliha pri čemu se proizvodnja obavlja za zalihe, za uglavnom nepoznate kupce
2. **nivo B2** – plasman po gotovosti prethodno primljenih narudžbi, s proizvodnjom uglavnom za poznate kupce i minimalnim zalihama

U ovom slučaju nivo B1 podrazumijeva sadašnji obujam unaprijed poznatih kupaca-narudžbi od 41% a za nivo B2 se uzima 50% veće poznavanje kupaca, odnosno 60% jer je obzirom na tržište i organiziranost promatranog objekta istraživanja nemoguće u kraćem vremenu postići veći stupanj unaprijed poznatih kupaca-narudžbi.

Nivo B2 je zapravo plasman s nešto većim postotkom unaprijed poznatih kupaca-narudžbi u odnosu na postojeće stanje jer do sada za dio tih kupaca-narudžbi nije bilo svih podataka o svim vrstama traženih proizvoda, njihovim količinama i rokovima isporuka.

3. Faktor C - način planiranja i praćenja

Način planiranja i praćenja podrazumijeva postupak i intenzitet zanavljanja i usklađivanja planova, potreba, stanja i realizacije proizvodnje i plasmana proizvoda s aspekta dinamike i prilagodljivosti izvođenja procesa planiranja i praćenja proizvodnje.

Ovdje se želi utvrditi djelovanje **kliznog planiranja i praćenja proizvodnje** kao predloženog modela prilagodljivog planiranja i praćenja i taj model treba biti 2. nivo faktora C-način planiranja i praćenja proizvodnje, pa će se kao dva nivoa tretirati sljedeći načini planiranja i praćenja proizvodnje:

1. **nivo C1** – statičko planiranje i praćenje, kalendarski
2. **nivo C2** – klizno planiranje i praćenje, prilagodljivo

Kako se na 2. nivou faktora C praktično radi o drugačijem načinu rada u procesu planiranja i praćenja proizvodnje, to će se morati uzeti u obzir kod kreiranja modela za oponašanje za sve tretmane u faktorskom planu pokusa kod kojih će faktor C biti na 2. nivou.

4. Faktor D - učestalost i vrijeme trajanja zastoja strojeva

Učestalost i vrijeme trajanja zastoja strojeva i opreme govori o zakonitostima po kojima se pojavljuju zastoji-nerad strojeva i opreme zbog nastalih kvarova te koliko dugo traju takvi zastoji pa drugim riječima te zakonitosti određuju vrijeme kada će se pojaviti neki zastoj stroja ili opreme i koliko će mu biti vremensko trajanje.

Za odabrani objekt istraživanja podaci o učestalosti i vremenu trajanja zastoja strojeva i opreme nalaze se u Prilogu 9.1-1. a ovdje su obrađeni na način da budu prilagođeni programu za oponašanje procesa te su grupirani za tri dijela proizvodnje, kako slijedi:

a. zakon učestalosti i vremena trajanja zastoja strojeva i opreme u proizvodnji dijelova
b. zakon učestalosti i vremena trajanja zastoja strojeva i opreme u proizodnji poluproizvoda
c. zakon učestalosti i vremena trajanja zastoja strojeva i opreme u proizvodnji gotovih proizvoda

Kada se broj godišnjih radnih sati podijeli s brojem zastoja grupe strojeva ili opreme tokom godine dobije se razmak pojave njihovog zastoja na temelju čega se izračuna aritmetička sredina i standardna devijacija, odnosno rasipanje u svakoj proizvodnji. Zakonitost trajanja zastoja strojeva i opreme je uzeta za svaki dio proizvodnje uprosječivanjem vjerojatnosti trajanja kod svake grupe strojeva i opreme, prema grafičkim prikazima na slikama 10., 11. i 12.

Za prvi nivo D1 ovog utjecajnog faktora uzimaju se po svakom dijelu proizvodnje utvrđeni zakon učestalosti i vremena trajanja zastoja strojeva i opreme, i to:

a. proizvodnja dijelova

- učestalost zastoja: 3,07 +/- 1,56 dana (47 +/- 25 sati)

- vrijeme trajanja sati):	2	4	8	16	32	48
vjerojatnost:	0,12	0,23	0,16	0,24	0,14	0,11

b. proizvodnja poluproizvoda

- učestalost zastoja: 2,56 +/- 1,54 dana (41 +/- 25 sati)

- vrijeme trajanja (sati):	1	2	4	8	16	32
vjerojatnost:	0,14	0,27	0,23	0,14	0,06	0,06

c. proizvodnja poluproizvoda

- učestalost zastoja: 4,62 +/- 3,11 dana (74 +/- 50 sati)

- vrijeme trajanja (sati):	2	4	8	16	32	48
vjerojatnost:	0,12	0,26	0,18	0,21	0,14	0,09

Sljedećom distrubucijom vjerojatnosti utvrđuje se koji se proizvod prestaje proizvoditi kod zastoja stroja ili opreme:

- grupa proizvoda:	P1	P2	P3	P4	P5	P6
- vjerojatnost:	0,25	0,04	0,19	0,26	0,14	0,12

Procjenjuje se da se u promatranom sustavu sa sigurnošću može učestalost zastoja smanjiti za 1/3 pa bi se razmak između zastoja povećao za 50%. Sličan odnos smanjenja može se dati i po pitanju vremena trajanja zastoja uz dobru pripremu održavanja pa se pretpostavlja da bi se tada proporcionalno povećale vjerojatnosti svih kraćih vremena zastoja.

Prema navedenom, nivoi tretmana faktora učestalosti i vremena trajanja zastoja strojeva i opreme bili bi kako slijedi:

1. **nivo D1** – sadašnji zakoni učestalosti i vremena trajanja zastoja
2. **nivo D2** – učestalost i vrijeme trajanja zastoja manje za 1/3 od sadašnjeg

U skladu s datim procjenama, učestalost i vrijeme trajanja zastoja strojeva i opreme na drugom nivou D2 ovog faktora imati će sljedeće zakonitosti:

a. proizvodnja dijelova

- učestalost zastoja: 4,60 +/- 1,56 dana (74 +/- 25 sati)

- vrijeme trajanja sati):	2	4	8	16	32
vjerojatnost:	0,14	0,25	0,18	0,27	0,16

b. proizvodnja poluproizvoda

- učestalost zastoja: 3,76 +/- 1,54 dana (61 +/- 25 sati)

- vrijeme trajanja (sati):	1	2	4	8	16
vjerojatnost:	0,15	0,29	0,24	0,15	0,07

c. proizvodnja poluproizvoda

- učestalost zastoja: 6,93 +/- 3,11 dana (110 +/- 50 sati)

- vrijeme trajanja (sati):	2	4	8	16	32
vjerojatnost:	0,13	0,28	0,20	0,23	0,16

5. <u>Faktor E</u> - <u>čestalost i vrijeme trajanja zastoja čovjeka</u>

Ovaj složeni utjecajni faktor govori po kojim se zakonitostima pojavljuje nerad ili drugi oblici poremećaja u radu čovjeka, koliko dugo traju i gdje se događaju, pri čemu su ovdje obuhvaćeni učestalost i vremena trajanja zastoja čovjeka iz subjektivnih razloga u svim fazama proizvodnje, nabavi, prodaji, otpremi te operativnom planiranju i praćenju proizvodnje. Pošto nema značajnije razlike u ponašanju izvršilaca po pojedinim fazama proizvodnje, za istraživanje je uzeta jedinstvena zakonitost pojave i trajanja zastoja.

Vrijeme pojave zastoja čovjeka u proizvodnji dobiva se dijeljenjem godišnjeg broja radnih sati s brojem zastoja grupe izvršilaca u jednoj godini, što predstavlja razmak između dvije pojave zastoja čovjeka. Prema tim pojedinačnim podacima izračunava se aritmetička sredina i standardna devijacija, odnosno rasipanje jedinstveno za cijelu proizvodnju.

Vjerojatnost prestanka proizvodnje neke grupe proizvoda kod zastoja čovjeka uzeti će se po zakonu vjerojatnosti kao kod zastoja strojeva i opreme.

Zastoji i poremećaji kod izvršilaca u nabavi, prodaji i otpremi manifestiraju se u kašnjenju dopreme repromaterijala, odnosno isporuci gotovih proizvoda a što se događa u 8% slučajeva pri čemu u 5% slučajeva zastoj traje jedan dan a u 3% slučajeva dva dana. Zastoji i poremećaji kod izvršioca u operativnom planiranju i praćenju ogledaju se ukupno u kašnjenju od jednog tjedna u izradi mjesečnog plana a što se događa u 27% slučajeva.

Prema navedenom, možemo računati sa sljedećim zakonitostima zastoja i poremećaja kod izvršioca o procesima rada kako slijedi:

a. proizvodnja

- učestalost zastoja: 2,63 +/- 1,55 dana (42 +/- 25 sati)

- vrijeme trajanja sati):	1	2	3	4	8
vjerojatnost:	0,30	0,23	0,10	0,21	0,16

b. nabava, prodaja, otprema

- učestalost zastoja: 2,63 +/- 1,55 dana (42 +/- 25 sati)

- vrijeme trajanja (sati):	1	2	3	4	8
vjerojatnost:	0,29	0,15	0,10	0,22	0,24

c. doprema i otprema

- vrijeme trajanja u danima (sati): 0 1 (16) 2 (32)

vjerojatnost: 0,92 0,05 0,03

d. operativan priprema (izrada mjesečnog plana)

- vjerojatnost kašnjenja od 1 tjedan: 0,27

Prema navedenom, nivoi tretmana faktora učestalosti i vremena trajanja zastoja čovjeka bili bi kako slijedi:

1. **nivo E1** – sadašnji zakon učestalosti i vremena trajanja zastoja
2. **nivo E2** – učestalost i vrijeme trajanja zastoja manje za 1/3 od sadašnjeg

U skladu s datim procjenama, učestalost i vrijeme trajanja zastoja strojeva i opreme na drugom nivou E2 ovog faktora imati će sljedeće zakone vjerojatnosti:

a. učestalost zastoja: 3,94 +/- 1,55 dana (63 +/- 25 sati)

b. vrijeme trajanja (sati): 1 2 3 4

vjerojatnost: 0,34 0,27 0,14 0,25

c. kašnjenja u dopremi i otpremi

- broj dana (sati): 0 (0) 1 (16) 2 (32)

vjerojatnost: 0,94 0,04 0,02

d. vjerojatnost kašnjenja u izradi mjesečnog plana od 1 tjedan: 0,18

5. ISTRAŽIVANJE NA MODELU

5.1. Primjena modela za istraživanje

Istraživanje modela prilagodljivog planiranja i praćenja proizvodnje započeto je primjenom modela za oponašanje opisanom u poglavlju 3.3.3. na stranici 52., uz korištenje podataka iz odabranog praktičnog primjera opisanog u poglavlju 4. na stranici 60. Oponašanjem su dobiveni rezultati za faktorski plan pokusa i analizu varijance.

Prema prethodno detaljno definiranom postupku oponašanja sa svim potrebnim algoritmima, izrađen je i testiran program za rad na računalu. Program je oponašao rad pet dana u tjednu u dvije smjene što je dalo ukupno 320 sati rada mjesečno, umjesto stvarnih 364 sati, pa je korekcijom parametara i zakonitosti ta razlika u zadovoljavajućoj mjeri uklonjena. Oponašan je proces u trajanju od godinu dana što je uz terminsku jedinicu TJ=1 sat dalo 3840 TJ u ukupnom vremenu oponašanja koje je trajalo 6,5 do 8,0 minuta po jednom pokusu, ovisno o nivou tretiranih utjecajnih faktora.

Zapravo se radilo s četiri varijante programa oponašanja dobivenih prema kombinacijama faktora B i faktora C, i to:.

1. I. varijanta – faktori B i C su na prvom nivou, način rada kao postojeći
2. II. varijanta – faktor B na drugom nivou a faktor C na prvom nivou, način rada je za poznatog kupca sa statičkim planiranjem i praćenjem proizvodnje
3. III. varijanta – faktor B na prvom nivou a faktor C na drugom nivou, način rada je s isporukama sa skladišta uz klizno planiranje i praćenje proizvodnje
4. IV. varijanta – faktori B i C su na drugom nivou, način rada je za poznatog kupca sa kliznim planiranjem i praćenjem proizvodnje

Najveća pojednostavljenja u modelu oponašanja su napravljena za proces prodaje, za što su izvršene dvije transformacije ulaznih podataka prema utvrđenim zakonitostima.

Kod prve transformacije ulaznih podataka utvrđeno stanje prodaje prikazano u poglavlju 4.2. i pripadajućim prilozima pretvoreno je u prikaz koji je dat u tablici 3., uz korištenje utvrđenih, potrebnih zakonitosti. U tablici 4. prikazana je druga transformacija podataka iz prodaje u formi za unos u računalo kao grupe ulaznih podataka zbog lakšeg pretraživanja. Istovremeno su označeni statusi narudžbi-isporuka s obzirom na 1. i 2. nivo faktora A – intenzitet prikupljanja ulaznih informacija.

Tablica 5. prikazuje matricu nabave repromaterijala – sirovina i dijelova dobivenu transformacijama podataka po utvrđenom stanju u poglavlju 4.3. i pripadajućim prilozima, korištenjem snimljenog stanja i zakonitosti u području nabave. Prilikom oponašanja posebnim se algoritmom određivao nivo potrebnih zaliha proizvoda i repromaterijala te količina repromaterijala za naručivanje, u skladu s prikupljenim raspoloživim informacijama o potrebama kupaca.

Završetkom oponašanja svakog pokusa ispisani su u terminskoj jedinici pojave TJ sljedeći podaci:

a. proteklo vrijeme (svake TJ)
b. planovi prodaje
c. planovi i normativi proizvodnje dijelova, poluproizvoda i proizvoda
d. narudžbe repromaterijala - sirovina i dijelova
e. proizvedene količine dijelova, poluproizvoda i proizvoda
f. prosječne dnevne, tjedne i mjesečne zalihe repomaterijala
g. prosječne dnevne, tjedne i mjesečne zalihe dijelova, poluproizvoda i proizvoda
h. zastoji, kašnjenja i reklamacije

Svi dobiveni izlazni podaci su na kraju sortirani na način da se mogu koristiti za izračun svih pokazatelja prema svim odabranim kriterijima i mjerilima za svaki pokus i njihovo ponavljanje, a što je obuhvatilo sljedeće podatke:

- x_{1ij} - omjer 1/12 godišnjeg plana GP i mjesečne prodaje svake grupe proizvoda
- x_{2ij} - omjer mjesečnog plan MP i mjesečne prodaje svake grupe proizvoda
- x_{3ij} - omjer mjesečne proizvodnje PR i mjesečne prodaje svake grupe proizvoda
- x_{4ij} - omjer plana i proizvodnje s mjesečnom prodajom svake grupe proizvoda
- R - ukupni godišnji broj postavljenih rokova (dana za isporuke)
- R_z - godišnji broj nepoštivanih rokova isporuke (s kašnjenjem)
- $\bar{x}_z$ - prosječni broj dana kašnjenja
- $\bar{x}_{DI}$ - prosječan broj dana postavljen kao rok isporuke
- $(\bar{z}_p)_{ij}$ – prosječno dnevno stanje zaliha grupe proizvoda u svakom mjesecu
- $(\bar{x}_p)_{ij}$– količina isporučene grupe proizvoda u svakom mjesecu
- $(\bar{z}_s)_{ij}$– prosječno dnevno stanje zaliha svake sirovine u svakom mjesecu
- $(\bar{x}_{us})_{ij}$– količina utrošene svake sirovine u svakom mjesecu

Tablica 3. *Prva transformacija podataka tržišta prodaje*

			SVI KUPCI SVIH PROIZVODA →							
			KP1	. . . .	**KP1**$_{j1}$	. . . . .	**KP2**	. . . . .	**KP2**$_{j2}$	. . .
S	a. Količina za prvu isporuku	QI1	$QI1_{111}$		$QI1_{1j1}$		$QI1_{211}$		$QI1_{21j}$	
I	b. Količina za drugu isporuku	QI2	$QI2_{111}$		$QI2_{1j1}$		$QI2_{211}$		$QI2_{21j}$	
J	c. Datum prve isporuke	DI1	$DI1_{111}$		$DI1_{1j1}$		$DI1_{211}$		$DI1_{21j}$	
E	d. Datum druge isporuke	DI2	$DI2_{111}$		$DI1_{1j1}$		$DI2_{211}$		$DI2_{21j}$	
Č	e. Reklamirana količina	RQI	RQI_{111}		RQI_{1j1}		RQI_{211}		RQI_{21j}	
A	f. Datum dojave reklamacije	DR	DR_{111}		DR_{1j1}		DR_{211}		DR_{21j}	
N	g. Količina izvanredne narudžbe	VQI	VQI_{111}		VQI_{1j1}		VQI_{211}		VQI_{21j}	
J	h. Datum pojave izvan. narudžbe	VDN	VDN_{111}		VDN_{1j1}		VDN_{211}		VDN_{21j}	
(I.)	i. Datum isporuke izvanred. narudž.	VDI	VDI_{111}		VDI_{1j1}		VDI_{211}		VDI_{21j}	
M J E S E C I U G O D I N I										
i	a. Količina za prvu isporuku	QI1	$QI1_{1i1}$		$QI1_{1ij}$		$QI1_{2i1}$		$QI1_{2ij}$	
	b. Količina za drugu isporuku	QI2	$QI2_{1i1}$		$QI2_{1ij}$		$QI2_{2i1}$		$QI2_{2ij}$	
M	c. Datum prve isporuke	DI1	$DI1_{1i1}$		$DI1_{1ij}$		$DI1_{2i1}$		$DI1_{2ij}$	
J	d. Datum druge isporuke	DI2	$DI2_{1i1}$		$DI2_{1ij}$		$DI2_{2i1}$		$DI2_{2ij}$	
E	e. Reklamirana količina	RQI	RQI_{1i1}		RQI_{1ij}		RQI_{2i1}		RQI_{2ij}	
S	f. Datum dojave reklamacije	DR	DR_{1i1}		DR_{1ij}		DR_{2i1}		DR_{2ij}	
E	g. Količina izvanredne narudžbe	VQI	VQI_{1i1}		VQI_{1ij}		VQI_{2i1}		VQI_{2ij}	
C	h. Datum pojave izvan. narudžbe	VDN	VDN_{1i1}		VDN_{1ij}		VDN_{2i1}		VDN_{2ij}	
	i. Datum isporuke izvanred. narudž.	VDI	VDI_{1i1}		VDI_{1ij}		VDI_{2i1}		VDI_{2ij}	

Tumačenje:

QI1kij

- QI1 → količina za isporuku
- i → broj isporuke u mjesecu
- k → grupa proizvoda (k=1, 2,. . . . 6)
- j → kupac nekog proizvoda
- i → mjesec u godini (i=1, 2, ... 12)

Tablica 4. *Druga transformacija podataka tržišta prodaje*

		MJESECI U GODINI → (**i**)										
		SIJEČANJ			. . . . .	**i** – MJESEC				PROSINAC		
		Status isporuke	Količ. za isporuku	Datum isporuke		Status isporuke	Količ. za isporuku	Datum isporuke		Status isporuke	Količ. za isporuku	Datum isporuke
		NI	QI	DI		NI	QI	DI		NI	Q I	DI
SVI ZAHTJEVI-KUPCI ZA PROIZVODE (**j**)	$P1_1$	SI	QI_{111}	DI_{111}		SI	QI_{111}	DI_{111}		SI	QI_{111}	DI_{111}
	. . . .											
	. . . .											
	$P1_j$	SI	QI_{11j}	DI_{11j}		SI	QI_{111}	DI_{111}		SI	QI_{111}	DI_{111}
	. . . .											
	$P2_1$	SI	QI_{211}	DI_{211}		SI	QI_{2i1}	DI_{2i1}		SI	QI_{2121}	DI_{2121}
	. . . .											
	. . . .											
	$P2_j$	SI	QI_{21j}	DI_{21j}		SI	QI_{2ij}	DI_{2ij}		SI	QI_{212j}	DI_{212j}
	. . . .											
	$P6_1$	SI	QI_{611}	DI_{611}		SI	QI_{6i1}	DI_{6i1}		SI	QI_{6121}	DI_{6121}
	…..											
	…..											
	$P6_j$	SI	QI_{61j}	DI_{61j}		SI	QI_{6ij}	DI_{6ij}		SI	QI_{612j}	DI_{612j}

SI = 0, 1, 2, x

0 – narudžba koja nije prethodno poznata na tržištu
1 – narudžba prethodno upoznata na tržištu
2 – narudžba prethodno upoznata na tržištu kada je veći intenzitet prikupljanja ulaznih informacija (faktor A na 2. nivou)
x – ugovorene i unaprijed poznate informacije

Tumačenje:

QI_{kij}

- Q → količina za isporuku
- k → grupa proizvoda (k=1, 2,. . . . 6)
- j → kupac nekog proizvoda
- i → mjesec u godini (i=1, 2, ... 12)

Tablica 5. *Matrica nabave sirovina i dijelova*

				MOGUĆNOSTI IZBORA KOD NARUČIVANJA (MN)				
				Varijanta MN_1		. . . . .	Varijanta MN_k	
Sirovine i dijelovi	Status dobave	Dobavljači	Jedinične cijene	Moguća količina za dobavu QSD	Mogući rok za dobavu RD		Moguća količina za dobavu QSD	Mogući rok za dobavu RD
S_1	SN_l	SD_{11}	SC_{11}	QSD_{111}	RD_{111}		QSD_{11k}	RD_{11k}
	. . . .	. . . . .	. . . . .	. . . . .	. . . . .	. . . . .	. . . . .	. .
	. . . .	. . . . .	. . . . .	. . . . .	. . . . .	. . . . .	. . . . .	. .
	SN_l	SD_{1j}	SC_{1j}	QSD_{1j1}	RD_{1j1}		QSD_{1jk}	RD_{1jk}
	. . . .	. . . . .	. . . . .	. . . . .	. . . . .	. . . . .	. . . . .	. .
. . .	. . .	. . .	. . .	. . .	. . .	. . . . .	. . . .	.
S_i	SN_l	SD_{ij}	SC_{ij}	QSD_{ij1}	RD_{ij1}		QSD_{ijk}	RD_{ijk}

SN_l = 1, 2

1 – mogućnosti nabave su upoznate na tržištu na 1. nivou faktora A

2 – dodatne mogućnosti nabave upoznate su na tržištu prilikom intenzivnijeg prikupljanja informacija, kada je faktor A na 2. nivou

5.2. Dobiveni rezultati pokusa

Prije početka proučavnja rezultata dobivenih oponašanjem i faktorskim planom pokusa izvršeno je putem **t**-testa testiranje vjerodostojnosti modela oponašanja u odnosu na stvarni proces usporedbom dobivenih rezultata po navedenim kriterijima u stvarnosti i onih dobivenih oponašanjem, kako je to prikazano u tablici 6.

Tablica 6. *Usporedba i testiranje pokazatelja uspješnosti planiranja u stvarnosti i na modelu*

Kriterij i mjesto ocjenjivanja		Dobiveni rezultati x_i	(s)²	s_d	t
1. Osjetljivost planiranja $\mathbf{U_1}$	1.1. sistem, n=5 god.	0,798	0,0006	0,022	$t_{rač.}$ =0,636
	1.2. model, n=6 ponav.	0,784	0,0004	0,022	$t_{\alpha=0,025}$=2,685
2. Zadovoljenost rokova $\mathbf{U_1}$	2.1. sistem, n=5 god.	0,787	0,0007	0,023	$t_{rač.}$ =0,956
	2.2. model, n=6 ponav.	0,765	0,0004	0,023	$t_{\alpha=0,025}$=2,685
3. Efikasnost zaliha $\mathbf{U_1}$	3.1. sistem, n=5 god.	0,957	0,0022	0,043	$t_{rač.}$ =1,791
	3.2. model, n=6 ponav.	1,034	0,0016	0,043	$t_{\alpha=0,025}$=2,685
4. Uspješnost planiranja **U**	4.1. sistem, n=5 god.	0,601	0,0011	0,030	$t_{rač.}$ =0,667
	4.2. model, n=6 ponav.	0,621	0,0007	0,030	$t_{\alpha=0,025}$=2,685

Dobiveni podaci su putem odgovarajućeg programa obrade podataka sortirani i obrađeni kako bi se dobili podaci-elementi za izračun pokazatelja po tri odabrana kriterija i mjerila prema kojima su dobiveni konačni izlazni podaci. To su pokazatelji U_1- osjetljivost planiranja i praćenja, U_2- zadovoljenost rokova i U_2- efikasnost upravljanja zalihama, za svih 6 ponavljanja pokusa, kako je to prikazano u tablici 7. U istoj tablici prikazani su i izvedeni podaci za kriterij U – uspješnost planiranja i praćenja za svaki od izvedenih pokusa, a koji su dobiveni prema izrazu (17) za sintetski kriterij U gdje je $U = U_1 \cdot U_2 \cdot U_3$

Proučavanje dobivenih rezultata oponašanja, odnosno pokusa, obavljeno je putem analize varijance koja se preporuča za obradu rezultata pokusa u kojima je prisutan faktor čovjek, što vrijedi za sve pokuse u području organizacije. Pri tome su utvrđeni efekti **E** djelovanja svakog utjecajnog faktora i njihovih interakcija, izračunata varijanca $(\boldsymbol{\sigma_E})^2$ i nakon toga je utvrđena računska vrijednost $\mathbf{F_{rač.}}$ za svaki utjecajni faktor i interakcije.

Tablica 7. *Dobiveni rezultati pokusa po svim kriterijima i izvršenim ponavljanjima*

Rezultati pokusa po kriteriju U1						**Rezultati pokusa po kriteriju U2**						**Rezultati pokusa po kriteriju U3**						**Rezultati pokusa po kriteriju U**					
Ponavljanje pokusa						Ponavljanje pokusa						Ponavljanje pokusa						Ponavljanje pokusa					
1.	2.	3.	4.	5.	6.	1.	2.	3.	4.	5.	6.	1.	2.	3.	4.	5.	6.	1.	2.	3.	4.	5.	6.
0,770	0,812	0,785	0,764	0,802	0,780	0,750	0,765	0,792	0,782	0,744	0,759	1,058	1,002	1,011	0,984	1,112	1,035	0,611	0,622	0,629	0,588	0,664	0,613
0,823	0,803	0,808	0,790	0,780	0,797	0,798	0,768	0,773	0,749	0,740	0,758	1,021	1,135	1,087	1,056	1,038	1,004	0,671	0,700	0,679	0,625	0,599	0,607
0,792	0,799	0,770	0,781	0,810	0,784	0,788	0,799	0,765	0,771	0,810	0,784	1,068	1,023	1,094	1,177	1,128	1,078	0,667	0,653	0,644	0,709	0,740	0,663
0,815	0,833	0,795	0,799	0,804	0,823	0,803	0,784	0,779	0,773	0,813	0,795	1,186	1,243	1,137	1,206	1,162	1,295	0,776	0,812	0,704	0,745	0,760	0,847
0,802	0,798	0,820	0,782	0,770	0,806	0,791	0,755	0,767	0,805	0,781	0,787	1,035	1,071	1,124	0,994	1,052	1,146	0,657	0,645	0,707	0,626	0,633	0,727
0,866	0,876	0,890	0,859	0,865	0,854	0,809	0,800	0,815	0,845	0,831	0,822	1,135	1,224	1,084	1,123	1,187	1,156	0,795	0,858	0,786	0,815	0,853	0,811
0,794	0,813	0,796	0,813	0,790	0,824	0,854	0,819	0,845	0,826	0,841	0,834	1,271	1,382	1,324	1,315	1,341	1,258	0,862	0,920	0,891	0,883	0,891	0,865
0,786	0,815	0,808	0,810	0,826	0,800	0,818	0,846	0,830	0,828	0,836	0,808	1,214	1,290	1,246	1,325	1,276	1,298	0,781	0,889	0,836	0,889	0,881	0,839
0,771	0,803	0,816	0,778	0,787	0,778	0,760	0,796	0,783	0,767	0,757	0,751	1,010	1,051	1,098	1,042	1,028	1,071	0,592	0,672	0,702	0,622	0,612	0,626
0,788	0,827	0,808	0,833	0,817	0,798	0,767	0,778	0,797	0,803	0,787	0,758	1,080	1,045	1,153	1,026	1,106	1,067	0,653	0,672	0,743	0,686	0,711	0,645
0,802	0,834	0,806	0,823	0,797	0,811	0,791	0,818	0,787	0,796	0,780	0,808	1,154	1,087	1,133	1,176	1,043	1,122	0,732	0,742	0,719	0,770	0,648	0,735
0,810	0,835	0,805	0,821	0,807	0,845	0,845	0,807	0,821	0,804	0,835	0,810	1,230	1,173	1,260	1,222	1,302	1,253	0,842	0,790	0,833	0,807	0,877	0,858
0,814	0,792	0,830	0,804	0,807	0,813	0,827	0,804	0,816	0,792	0,812	0,808	1,063	1,124	1,197	1,102	1,135	1,158	0,716	0,716	0,811	0,702	0,744	0,761
0,862	0,895	0,882	0,867	0,895	0,872	0,802	0,835	0,817	0,807	0,842	0,813	1,170	1,247	1,284	1,225	1,192	1,260	0,809	0,932	0,925	0,857	0,898	0,893
0,815	0,838	0,806	0,820	0,828	0,798	0,821	0,852	0,830	0,835	0,813	0,843	1,344	1,244	1,315	1,321	1,335	1,382	0,899	0,888	0,880	0,904	0,899	0,930
0,812	0,800	0,847	0,840	0,809	0,818	0,823	0,814	0,843	0,852	0,805	0,817	1,309	1,255	1,296	1,275	1,237	1,336	0,875	0,817	0,925	0,912	0,806	0,893
0,797	0,787	0,836	0,813	0,793	0,806	0,796	0,787	0,777	0,825	0,803	0,783	1,023	1,117	1,008	1,056	1,045	1,078	0,649	0,692	0,655	0,708	0,665	0,680
0,808	0,843	0,832	0,826	0,801	0,817	0,801	0,776	0,792	0,783	0,815	0,807	1,080	1,107	1,100	1,123	1,191	1,030	0,699	0,724	0,725	0,726	0,778	0,679
0,810	0,845	0,813	0,829	0,818	0,832	0,823	0,813	0,828	0,805	0,838	0,809	1,105	1,115	1,140	1,132	1,074	1,211	0,737	0,766	0,767	0,755	0,736	0,815
0,824	0,836	0,814	0,827	0,800	0,842	0,857	0,815	0,843	0,829	0,850	0,838	1,331	1,223	1,266	1,273	1,198	1,301	0,940	0,833	0,869	0,873	0,815	0,918
0,812	0,829	0,795	0,825	0,805	0,816	0,839	0,820	0,831	0,827	0,843	0,810	1,115	1,132	1,140	1,168	1,088	1,191	0,760	0,770	0,753	0,797	0,738	0,787
0,855	0,880	0,862	0,890	0,886	0,878	0,843	0,850	0,855	0,827	0,845	0,820	1,267	1,214	1,241	1,284	1,235	1,260	0,913	0,908	0,915	0,945	0,925	0,907
0,837	0,804	0,841	0,810	0,832	0,822	0,839	0,853	0,845	0,861	0,829	0,868	1,312	1,345	1,359	1,303	1,385	1,455	0,921	0,922	0,966	0,909	0,955	1,038
0,820	0,800	0,843	0,811	0,845	0,812	0,842	0,864	0,841	0,873	0,829	0,851	1,317	1,287	1,388	1,344	1,320	1,265	0,909	0,890	0,984	0,952	0,925	0,874
0,827	0,805	0,824	0,845	0,841	0,830	0,820	0,831	0,836	0,813	0,795	0,817	1,055	1,024	1,075	1,082	1,095	1,149	0,715	0,685	0,741	0,743	0,732	0,779
0,825	0,820	0,807	0,831	0,845	0,830	0,809	0,819	0,805	0,800	0,795	0,781	1,090	1,076	1,115	1,120	1,179	1,113	0,727	0,723	0,724	0,745	0,792	0,721
0,810	0,834	0,807	0,823	0,798	0,815	0,812	0,831	0,825	0,848	0,822	0,837	1,187	1,154	1,215	1,080	1,115	1,170	0,781	0,800	0,809	0,754	0,731	0,798
0,820	0,839	0,845	0,852	0,831	0,847	0,857	0,836	0,852	0,825	0,843	0,849	1,382	1,294	1,267	1,320	1,292	1,213	0,971	0,908	0,912	0,928	0,905	0,872
0,852	0,827	0,820	0,843	0,838	0,830	0,837	0,834	0,825	0,846	0,821	0,816	1,156	1,084	1,172	1,201	1,134	1,180	0,824	0,748	0,793	0,857	0,780	0,799
0,885	0,878	0,896	0,881	0,900	0,862	0,813	0,849	0,825	0,840	0,823	0,832	1,187	1,220	1,258	1,286	1,215	1,267	0,854	0,909	0,930	0,952	0,900	0,909
0,822	0,810	0,845	0,840	0,825	0,832	0,842	0,849	0,865	0,860	0,845	0,852	1,302	1,382	1,354	1,336	1,370	1,363	0,901	0,950	0,990	0,965	0,955	0,966
0,822	0,828	0,844	0,805	0,834	0,815	0,835	0,855	0,825	0,863	0,847	0,841	1,368	1,267	1,353	1,344	1,269	1,392	0,939	0,897	0,942	0,934	0,896	0,954

Značajnost svakog od utjecajnih faktora i interakcija određena je prema njihovoj vrijednosti $\mathbf{F_{rač.}=(\sigma_E)^2/(\sigma_o)^2}$ u odnosu na kritičnu tabelarnu vrijednosti $\mathbf{F_{tab.}}$=2,20 kod **F**-raspodjele za vjerojatnost α=0,01 za veću vrijednost **F**, uz stupanj slobode glavnih efekata i interakcija 31 i stupanj slobode ostatka-pogrešaka S_{sp}=160 koji su izračunati po izrazima

$$S_{st} = 2^n - 1 \quad (22)$$

$$S_{su} = (2^n \times r) - 1 \quad (23)$$

$$S_{sp} = S_{su} - S_{st} \quad (24)$$

gdje je : n – broj faktora (5)

r – broj ponavljanja (6)

To znači da su svi faktori i interakcije kod kojih je utvrđeno da je $\mathbf{F_{rač.} > F_{tab.}}$ značajni po svojem djelovanju te je izvršeno proučavanje njihovog djelovanja.

U tablicama s prikazanim analizama varijance korišteni su izrazi i postupci kako slijedi:

$\Sigma Q = \Sigma Y^2 - (\Sigma Y)^2 / N$ (ukupna suma kvadrata odstupanja) gdje je N = n x r (25)

$\Sigma Qt = \Sigma(\delta e)^2$ (korigirana, protumačena suma kvadrata odstupanja) (26)

$Qp = \Sigma Q - \Sigma Qt$ (neprotumačeni ostatak-pogreška) (27)

$(\sigma_o)^2 = Qp / Ssp$ (varijanca ostatka) gdje je S_{sp}= 31 (28)

Analiza varijance je napravljena po svakom pojedinačnom kriteriju U_1, U_2 i U_3 te za sintetski kriterij U. Rezultati su prikazani u odgovarajućim tablicama te imaju navedene stupnjeve značaja S utjecajnih faktora i interakcija kod kojih je utvrđeno da je $\mathbf{F_{rač.} > F_{tab.}}$, a navedeni su po rangu označenog utjecaja i predznaku djelovanja + ili -.

Stupnjevi utjecaja označeni su po rangu kako slijedi:

1. VSSS – vrlo jaki utjecaj
2. SSS – jaki utjecaj
3. SS – izraženi utjecaj
4. S – značajan utjecaj

S obzirom na vjerojatnost pogrešaka i nedostatke modela oponašanja te iz razloga značaja pojedinih faktora, svi ovdje utvrđeni utjecajni faktori i interakcije 4. ranga utjecaja označenim sa S nisu posebno razmatrani jer se pretpostavlja da su rezultat slučajnosti i pogrešaka.

5.3. Analiza varijance za kriterij U_1

Analiza varijance za rezultate pokusa 2^5 po kriteriju U_1-osjetljivost planiranja i praćenja prikazana je u tablici 8. gdje se može vidjeti mala ukupna suma kvadrata odstupanja rezultata pokusa ΣQ, pri čemu je protumačena suma kvadrata odstupanja ΣQ_t osjetno veća od neprotumačenog ostatka, odnosno pogreške Q_p pa je i mala varijanca ostatka $(\sigma_o)^2$.

Iz odnosa varijance efekata i varijance ostatka $F_{rač.}$ utvrđena je značajnost utjecajnih faktora i interakcija kada im je $F_{rač.} > F_{tab.} = 2{,}20$ za vjerojatnost $\alpha = 0{,}01$ za veću vrijednost $F_{rač.}$ pa su izračunima u tablici 8. po rangu utvrđeni sljedeći utjecajni faktori i interakcije:

1. faktor A – intenzitet prikupljanja ulaznih informacija, utjecaj +VSSS
2. faktor C - način planiranja i praćenja, utjecaj +SSS
3. interakcija BC, utjecaj –SSS
4. faktor E – učestalost i vrijeme trajanja zastoja čovjeka, utjecaj +SSS
5. interakcija ABC, utjecaj –SSS
6. interakcija AB, utjecaj –SSS
7. faktor D – učestalost i vrijeme trajanja zastoja strojeva i opreme, utjecaj +SS
8. interakcija AC, utjecaj +SS
9. faktor B – način plasmana, utjecaj –SS

Rezultati pokusa dobiveni za pokazatelje po ovom kriteriju ukazuju na rast osjetljivosti planiranja i praćenja do kombinacije faktora AC nakon čega slijedi pad pokazatelja U_1 kod pokusa BC i ABC, s time da se prethodno pokazuje i pad kod faktora B na drugom nivou.

Može se konstatirati da ima faktora i interakcija sličnog značaja djelovanja, ali različitog predznaka, a tome je mogući uzrok struktura odabranog kriterija gdje se u odnos stavljaju planovi i realizacija na što navedeni, odabrani utjecajni faktori i interakcije različito djeluju.

Vidi se da faktor faktor A – intenzitet prikupljanja ulaznih informacija, utjecaj +VSSS, najjače i pozitivno djeluje na osjetljivost planiranja i praćenja, što je bilo i za očekivati kada se uzme u obzir da na to utječu i prikupljene informacije s tržišta kao i interne ulazne informacije, uključujući i podatke o stanju raspoloživih i potrebnih resursa. Stoga je bilo za očekivati malo odstupanje omjera planova i realizacije u odnosu na izvršeni plasman, a time značajno povećana osjetljivost planiranja i praćenja.

Faktor C - način planiranja i praćenja ima jaki pozitivni utjecaj +SSS jer omogućuje da se periodičkim korekcijama i uskladama planova i realizacije zadrži bolji omjer planova i realizacije, odnosno postigne veća osjetljivost planiranja i praćenja.

Tablica 8. *Analiza varijance za kriterij* $\boldsymbol{U_1}$ *u pokusima* $\boldsymbol{2^5}$ *x 6*

Pokusi U1		Dobiveni rezultati (Y_{ijklm})P_i u ponavljanjima P_i							Totali kombinacije tretmana									
R.br.	Stanje	P1	P2	P3	P4	P5	P6	**Σ Y_{Pi}**	Y_i+Y_{i+1} $Y_{i+1}-Y_i$	$(Y_i+Y_{i+1})'$ $(Y_{i+1}-Y_i)'$	$(Y_i+Y_{i+1})''$ $(Y_{i+1}-Y_i)''$	$(Y_i+Y_{i+1})'''$ $(Y_{i+1}-Y_i)'''$	$(Y_i+Y_{i+1})''''$ $(Y_{i+1}-Y_i)''''$	Div.	Efekti **E**	Varijanca $(\sigma_E)^2$	**Frač.** = σ_E^2/σ_o^2	Značaj i rang
1		0,770	0,812	0,785	0,764	0,802	0,780	**4,713**	9,514	19,119	38,782	78,146	157,890	192	0,82234			
2	a	0,823	0,803	0,808	0,790	0,780	0,797	**4,801**	9,605	19,663	39,364	79,744	2,134	96	0,02223	0,023719	**108,275**	+ VSSS(1)
3	b	0,792	0,799	0,770	0,781	0,810	0,784	**4,736**	9,988	19,400	39,659	1,290	-0,856	96	-0,00892	0,003816	**17,422**	- SS (9)
4	ab	0,815	0,833	0,795	0,799	0,804	0,823	**4,869**	9,675	19,964	40,085	0,844	-1,492	96	-0,01554	0,011594	**52,927**	- SSS (6)
5	c	0,802	0,798	0,820	0,782	0,770	0,806	**4,778**	9,604	19,649	0,668	-0,332	1,852	96	0,01929	0,017864	**81,549**	+ SSS (2)
6	ac	0,866	0,876	0,890	0,859	0,865	0,854	**5,210**	9,796	20,010	0,622	-0,524	0,868	96	0,00904	0,003924	**17,913**	+ SS (8)
7	bc	0,794	0,813	0,796	0,813	0,790	0,824	**4,830**	10,133	19,851	0,445	-0,852	-1,666	96	-0,01735	0,014456	**65,992**	- SSS (3)
8	abc	0,786	0,815	0,808	0,810	0,826	0,800	**4,845**	9,831	20,234	0,399	-0,640	-1,530	96	-0,01594	0,012192	**55,657**	- SSS (5)
9	d	0,771	0,803	0,816	0,778	0,787	0,778	**4,733**	9,759	0,221	-0,222	1,108	1,008	96	0,01050	0,005292	**24,158**	+ SS (7)
10	ad	0,788	0,827	0,808	0,833	0,817	0,798	**4,871**	9,890	0,447	-0,110	0,744	-0,092	96	-0,00096	0,000044	0,201	
11	bd	0,802	0,834	0,806	0,823	0,797	0,811	**4,873**	10,133	0,188	-0,125	0,472	-0,162	96	-0,00169	0,000137	0,624	
12	abd	0,810	0,835	0,805	0,821	0,807	0,845	**4,923**	9,877	0,434	-0,399	0,396	0,218	96	0,00227	0,000248	1,130	
13	cd	0,814	0,792	0,830	0,804	0,807	0,813	**4,860**	9,930	0,091	-0,372	-0,898	0,042	96	0,00044	0,000009	0,042	
14	acd	0,862	0,895	0,882	0,867	0,895	0,872	**5,273**	9,921	0,354	-0,480	-0,768	-0,110	96	-0,00115	0,000063	0,288	
15	bcd	0,815	0,838	0,806	0,820	0,828	0,798	**4,905**	10,312	0,133	-0,483	-0,766	-0,084	96	-0,00088	0,000037	0,168	
16	abcd	0,812	0,800	0,847	0,840	0,809	0,818	**4,926**	9,922	0,266	-0,157	-0,764	-0,036	96	-0,00037	0,000007	0,031	
17	e	0,797	0,787	0,836	0,813	0,793	0,806	**4,832**	0,088	0,091	0,544	0,582	1,598	96	0,01665	0,013300	**60,715**	+ SSS (4)
18	ae	0,808	0,843	0,832	0,826	0,801	0,817	**4,927**	0,133	-0,313	0,564	0,426	-0,446	96	-0,00465	0,001036	**4,729**	- S (10)
19	be	0,810	0,845	0,813	0,829	0,818	0,832	**4,947**	0,432	0,192	0,361	-0,046	-0,192	96	-0,00200	0,000192	0,876	
20	abe	0,824	0,836	0,814	0,827	0,800	0,842	**4,943**	0,015	-0,302	0,383	-0,046	0,212	96	0,00221	0,000234	1,069	
21	ce	0,812	0,829	0,795	0,825	0,805	0,816	**4,882**	0,138	0,131	0,226	0,112	-0,364	96	-0,00379	0,000690	**3,150**	- S (13)
22	ace	0,855	0,880	0,862	0,890	0,886	0,878	**5,251**	0,050	-0,256	0,246	-0,274	-0,076	96	-0,00079	0,000030	0,137	
23	bce	0,837	0,804	0,841	0,810	0,832	0,822	**4,946**	0,413	-0,009	0,263	-0,108	0,130	96	0,00135	0,000088	0,402	
24	abce	0,820	0,800	0,843	0,811	0,845	0,812	**4,931**	0,021	-0,390	0,133	0,326	0,002	96	0,00002	0,000000	0,000	
25	de	0,827	0,805	0,824	0,845	0,841	0,830	**4,972**	0,095	0,045	-0,404	0,020	-0,156	96	-0,00162	0,000127	0,579	
26	ade	0,825	0,820	0,807	0,831	0,845	0,830	**4,958**	-0,004	-0,417	-0,494	0,022	0,000	96	0,00000	0,000000	0,000	
27	bde	0,810	0,834	0,807	0,823	0,798	0,815	**4,887**	0,369	-0,088	-0,387	0,020	-0,386	96	-0,00402	0,000776	**3,543**	- S (12)
28	abde	0,820	0,839	0,845	0,852	0,831	0,847	**5,034**	-0,015	-0,392	-0,381	-0,130	0,434	96	0,00452	0,000981	**4,478**	+ S (11)
29	cde	0,852	0,827	0,820	0,843	0,838	0,830	**5,010**	-0,014	-0,099	-0,462	-0,090	0,002	96	0,00002	0,000000	0,000	
30	acde	0,885	0,878	0,896	0,881	0,900	0,862	**5,302**	0,147	-0,384	-0,304	0,006	-0,150	96	-0,00156	0,000117	0,535	
31	bcde	0,822	0,810	0,845	0,840	0,825	0,832	**4,974**	0,292	0,161	-0,285	0,158	0,096	96	0,00100	0,000048	0,219	
32	abcde	0,822	0,828	0,844	0,805	0,834	0,815	**4,948**	-0,026	-0,318	-0,479	-0,194	-0,352	96	-0,00367	0,000645	**2,946**	- S (14)
	Σ Y^2	**21,387**	**21,865**	**21,800**	**21,698**	**21,623**	**21,613**											
							Σ Y	**157,890**										

Ukupna suma kvadrata odstupanja Σ Q = Σ Y^2 - (Σ Y)^2 =	**0,146715**
Korigirana, protumačena suma kvadrata odstupanja Σ Qt =	**0,111666**
Neprotumačeni ostatak - pogreška Qp = Σ Q - Σ Qt =	**0,035049**

Stupanj slobode glavnih efekata interakcije, s n = 5 faktora, Sst = 2^n - 1 =	**31**
Stupanj slobode ukupni, s r = 6 ponavljanja, Ssu = (2^n x r) - 1 =	**191**
Stupanj slobode ostatka - pogreške, Ssp = Ssu - Sst =	**160**
Varijanca ostatka $(\sigma_o)^2$ = Qp / Ssp =	**0,000219**
Kritična tab. vrijednost Ftab kod F -raspodjele za prag značajnosti α= 0,01	**2,200**

Naime, stalnim uskladama planova i realizacije smanjuje se razlika između planiranog, realiziranog u proizvodnji i realiziranog na tržištu pa se povećava nivo točnosti a smanjuje varijacija odnosa planova i realizacije.

Interakcija BC ima jaki negativni utjecaj –SSS, vjerojatno iz razloga što se češćim uskladama planova i realizacije u odnosu na poremećaje u procesima više mijenjaju kako planovi tako i realizacija pa je manja osjetljivost planiranja i praćenja. Očigledno nema potrebe niti je preporučljivo kod rada za poznate kupce češće mijenjati i usklađivati planove pa o tome treba voditi računa kod izrade budućeg rješenja.

Utjecajni faktor E – učestalost i vrijeme trajanja zastoja čovjeka, utjecaj +SSS, također ima vrlo jako pozitivno djelovanje na osjetljivost planiranja jer svakom pravovremenom izvršenom aktivnosti od strane zaposlenih u promatranom procesu obuhvaća planiranja i praćenja. To znači da se manjim brojem izostanak i njihovim kraćim trajanjem na drugom nivou tretiranja u svim procesima unutar granica objekta istraživanja omogućava manje odstupanje realizacije od zacrtanih planova.

Interakcija AB ima jaki negativan utjecaj –SSS iz razloga što se prilikom rada za veći dio poznatih kupaca novim podacima sa tržišta remete zacrtani planovi i realizacija, kako proizvodnje tako i plasmana. Iz sličnih razloga i interakcija ABC ima jaki negativni utjecaj –SSS, ovdje dodatno iz razloga češćih promjena prilikom usklađivanja planova i realizacije.

Faktor D – učestalost i vrijeme trajanja zastoja strojeva i opreme ima izraženi pozitivni utjecaj +SS, a tome je razlog što se manjom učestalošću i manjim vremenima zastoja u realizaciji manje odstupa od zacrtanih planova, a što doprinosi osjetljivosti planiranja.

Interakcija AC ima izraženo pozitivno djelovanje i za tu kombinaciju faktora, kao i za slučaja kada je uz to pridodan faktor D, faktor E ili interakcija DE, ostvaruju se najveći pokazatelji uspješnosti planiranja i praćenja U.

Faktor B – način plasmana ima iznenađujuće izraženi negativni utjecaj –SS što se može tumačiti s jedne strane poremećajima koji remete izvršenje većeg broja fiksnih narudžbi i još uvijek velikog broja dodatnih narudžbi. S druge strane je moguće da drugi nivo ovog faktora nije na dovoljno visokom nivou da bi imali stabilne planove i realizaciju.

Svi ostali označeni faktori i interakcije imaju malo značajno djelovanje od kojih neki utjecaji nemaju logike što se može smatrati pogreškom modela oponašanja.

5.4. Analiza varijance za kriterij U_2

Analiza varijance za rezultate pokusa 2^5 po kriteriju U_2- zadovoljenost rokova prikazana je u tablici 9. I ovdje možemo vidjeti malu ukupnu sumu kvadrata odstupanja rezultata pokusa ΣQ pri čemu je protumačena suma kvadrata odstupanja ΣQ_t znatno veća od neprotumačenog ostatka, odnosno pogreške Q_p pa je i mala varijanca ostatka $(\sigma_o)^2$.

Iz odnosa varijance efekata i varijance ostatka $F_{rač.}$ utvrđena je značajnost utjecajnih faktora i interakcija kada im je $F_{rač.} > F_{tab.} = 2{,}20$ za vjerojatnost $\alpha = 0{,}01$ za veću vrijednost $F_{rač.}$ pa su izračunima u tablici 9. po rangu utvrđeni sljedeći utjecajni faktori i interakcije:

1. faktor C - način planiranja i praćenja, utjecaj +VSSS
2. faktor E – učestalost i trajanje zastoja čovjeka, utjecaj +VSSS
3. faktor B – oblik plasmana proizvoda, utjecaj +VSSS
4. interakcija ABC, utjecaj –SS
5. faktor D - učestalost i vrijeme trajanja zastoja strojeva i opreme, utjecaj +SS
6. faktor A – intenzitet prikupljanja ulaznih informacija, utjecaj +S
7. interakcije BC, CE i CD, utjecaj –S
8. interakcije ACDE i BCDE, utjecaj +S

Rezultati pokusa dobiveni za pokazatelje po ovom kriteriju ukazuju na rast osjetljivosti planiranja i praćenja do kombinacije faktora BC nakon čega slijedi pad pokazatelja U_2 kod pokusa ABC. Primjetno je manje povećanje pokazatelja U_2 kod svih pokusa gdje je prisutan faktor E u odnosu na analogne kombinacije faktora, a u kojima nije faktor E.

Također se primjećuje osjetno manji utjecaj bilo koje interakcije faktora te mali utjecaj faktora A – intenzitet prikupljanja ulaznih informacija.

Utjecajni faktor C-način planiranja i praćenja ima ovdje najjače pozitivno djelovanje na zadovoljenost rokova. Prema opisanom principu kliznog planiranja i praćenja kao drugog nivo tog faktora, tu se intenzivnim periodičkim izmjenama i dopunama promatranih planova i realizacije proizvodnje postiže veća mogućnost obuhvata aktualnih informacija na tržištu o potrebama kupaca i rokovima isporuka pa se raspolaže s više točnih i kompletnih podataka o traženim rokovima isporuka kupcima.

Vrlo jako izraženi pozitivan utjecaj ima i faktor E-učestalost i trajanje zastoja čovjeka jer se manjim brojem izostanak i njihovim kraćim trajanjem na drugom nivou tretiranja u svim procesima unutar granica objekta istraživanja povećava i točnost planova. Pouzdanija je i veća realizacija pa se poboljšavaju elementi pokazatelja zadovoljenost rokova U_2.

***Tablica 9**. Analiza varijance za kriterij U_2 u pokusima 2^5 x 6*

Pokusi U2		Dobiveni rezultati (Y_{ijklm})Pi u ponavljanjima Pi							Totali kombinacije tretmana									
R.br.	Stanje	P1	P2	P3	P4	P5	P6	**Σ YPi**	Y_i+Y_{i+1} $Y_{i+1}-Y_i$	$(Y_i+Y_{i+1})'$ $(Y_{i+1}-Y_i)'$	$(Y_i+Y_{i+1})''$ $(Y_{i+1}-Y_i)''$	$(Y_i+Y_{i+1})'''$ $(Y_{i+1}-Y_i)'''$	$(Y_i+Y_{i+1})''''$ $(Y_{i+1}-Y_i)''''$	Diviz.	Efekti **E**	Varijanca $(\sigma_E)^2$	**Frač.** = σ_E^2/σ_o^2	Značaj i rang
1		0,750	0,765	0,792	0,782	0,744	0,759	**4,592**	9,178	18,642	38,235	76,964	156,560	192	0,81542			
2	a	0,798	0,768	0,773	0,749	0,740	0,758	**4,586**	9,464	19,593	38,729	79,596	0,576	96	0,00600	0,001728	**7,765**	+S (6)
3	b	0,788	0,799	0,765	0,771	0,810	0,784	**4,717**	9,608	19,006	39,698	0,442	2,356	96	0,02454	0,028910	**129,912**	+VSSS (3)
4	ab	0,803	0,784	0,779	0,773	0,813	0,795	**4,747**	9,985	19,723	39,898	0,134	-0,096	96	-0,00100	0,000048	0,216	
5	c	0,791	0,755	0,767	0,805	0,781	0,787	**4,686**	9,304	19,493	0,207	1,234	2,762	96	0,02877	0,039733	**178,545**	+VSSS (1)
6	ac	0,809	0,800	0,815	0,845	0,831	0,822	**4,922**	9,702	20,205	0,235	1,122	-0,114	96	-0,00119	0,000068	0,304	
7	bc	0,854	0,819	0,845	0,826	0,841	0,834	**5,019**	9,775	19,758	0,194	-0,284	-0,450	96	-0,00469	0,001055	**4,739**	-S (10)
8	abc	0,818	0,846	0,830	0,828	0,836	0,808	**4,966**	9,948	20,140	-0,060	0,188	-0,906	96	-0,00944	0,004275	**19,211**	-SS (4)
9	d	0,760	0,796	0,783	0,767	0,757	0,751	**4,614**	9,545	0,024	0,663	1,668	0,694	96	0,00723	0,002509	**11,272**	+SS (5)
10	ad	0,767	0,778	0,797	0,803	0,787	0,758	**4,690**	9,948	0,183	0,571	1,094	-0,226	96	-0,00235	0,000266	1,195	
11	bd	0,791	0,818	0,787	0,796	0,780	0,808	**4,780**	10,010	0,218	0,588	-0,042	-0,146	96	-0,00152	0,000111	0,499	
12	abd	0,845	0,807	0,821	0,804	0,835	0,810	**4,922**	10,195	0,017	0,534	-0,072	0,314	96	0,00327	0,000514	**2,308**	+S (14)
13	cd	0,827	0,804	0,816	0,792	0,812	0,808	**4,859**	9,721	0,119	-0,253	-0,134	-0,564	96	-0,00587	0,001657	**7,445**	-S (8)
14	acd	0,802	0,835	0,817	0,807	0,842	0,813	**4,916**	10,037	0,075	-0,031	-0,316	-0,344	96	-0,00358	0,000616	**2,770**	-S (13)
15	bcd	0,821	0,852	0,830	0,835	0,813	0,843	**4,994**	9,961	-0,016	0,048	-0,488	-0,196	96	-0,00204	0,000200	0,899	
16	abcd	0,823	0,814	0,843	0,852	0,805	0,817	**4,954**	10,179	-0,044	0,140	-0,418	0,100	96	0,00104	0,000052	0,234	
17	e	0,796	0,787	0,777	0,825	0,803	0,783	**4,771**	-0,006	0,286	0,951	0,494	2,632	96	0,02742	0,036080	**162,133**	+VSSS (2)
18	ae	0,801	0,776	0,792	0,783	0,815	0,807	**4,774**	0,030	0,377	0,717	0,200	-0,308	96	-0,00321	0,000494	**2,220**	-S (15)
19	be	0,823	0,813	0,828	0,805	0,838	0,809	**4,916**	0,236	0,398	0,712	0,028	-0,112	96	-0,00117	0,000065	0,294	
20	abe	0,857	0,815	0,843	0,829	0,850	0,838	**5,032**	-0,053	0,173	0,382	-0,254	0,472	96	0,00492	0,001160	**5,214**	+S (9)
21	ce	0,839	0,820	0,831	0,827	0,843	0,810	**4,970**	0,076	0,403	0,159	-0,092	-0,574	96	-0,00598	0,001716	**7,711**	-S (7)
22	ace	0,843	0,850	0,855	0,827	0,845	0,820	**5,040**	0,142	0,185	-0,201	-0,054	-0,030	96	-0,00031	0,000005	0,021	
23	bce	0,839	0,853	0,845	0,861	0,829	0,868	**5,095**	0,057	0,316	-0,044	0,222	-0,182	96	-0,00190	0,000173	0,775	
24	abce	0,842	0,864	0,841	0,873	0,829	0,851	**5,100**	-0,040	0,218	-0,028	0,092	0,070	96	0,00073	0,000026	0,115	
25	de	0,820	0,831	0,836	0,813	0,795	0,817	**4,912**	0,003	0,036	0,091	-0,234	-0,294	96	-0,00306	0,000450	2,023	
26	ade	0,809	0,819	0,805	0,800	0,795	0,781	**4,809**	0,116	-0,289	-0,225	-0,330	-0,282	96	-0,00294	0,000414	1,861	
27	bde	0,812	0,831	0,825	0,848	0,822	0,837	**4,975**	0,070	0,066	-0,218	-0,360	0,038	96	0,00040	0,000008	0,034	
28	abde	0,857	0,836	0,852	0,825	0,843	0,849	**5,062**	0,005	-0,097	-0,098	0,016	-0,130	96	-0,00135	0,000088	0,396	
29	cde	0,837	0,834	0,825	0,846	0,821	0,816	**4,979**	-0,103	0,113	-0,325	-0,316	-0,096	96	-0,00100	0,000048	0,216	
30	acde	0,813	0,849	0,825	0,840	0,823	0,832	**4,982**	0,087	-0,065	-0,163	0,120	0,376	96	0,00392	0,000736	**3,309**	+S (12)
31	bcde	0,842	0,849	0,865	0,860	0,845	0,852	**5,113**	0,003	0,190	-0,178	0,162	0,436	96	0,00454	0,000990	**4,449**	+S (11)
32	abcde	0,835	0,855	0,825	0,863	0,847	0,841	**5,066**	-0,047	-0,050	-0,240	-0,062	-0,224	96	-0,00233	0,000261	1,174	
	Σ Y²	**21,331**	**21,351**	**21,361**	**21,416**	**21,266**	**21,098**											
							Σ Y	**156,560**										

Ukupna suma kvadrata odstupanja Σ Q = Σ Y² - (Σ Y)² =	**0,160061**
Korigirana, protumačena suma kvadrata odstupanja Σ Qt =	**0,124455**
Neprotumačeni ostatak - pogreška Qp = Σ Q - Σ Qp =	**0,035606**

Stupanj slobode glavnih efekata interakcije, s n = 5 faktora, Sst = 2^n - 1 =	**31**
Stupanj slobode ukupni, s r = 6 ponavljanja, Ssu = (2^n x r) - 1 =	**191**
Stupanj slobode ostatka - pogreške, Ssp = Ssu - Sst =	**160**
Varijanca ostatka $(\sigma_o)^2$ = Qp / Ssp =	**0,000223**
Kritična tab. vrijednost Ftab kod F -raspodjele za prag značajnosti α= 0,01	**2,200**

Sljedeći po rangu je faktor B-oblik plasmana proizvoda koji vrlo jako i pozitivno djeluje na zadovoljenost rokova, što je također bilo i za očekivati kada se zna da se 60% kupaca pozna po točno i unaprijed traženim godišnjim i mjesečnim količinama proizvoda i rokovima isporuka. Stoga je za očekivati da će se preciznijom izradom planova osigurati manje odstupanje rokova isporuka od traženih i time će se značajno povećati zadovoljenost rokova.

Interakcija ABC ima izraženi negativan utjecaj što se može obrazložiti promjenama u realizaciji kada se kliznim planiranjem i praćenjem, faktor C na drugom nivou, temeljem većeg broja ulaznih informacija mijenjaju rokovi realizacije narudžbi već poznatih kupaca, tj. kada su i faktori A i B na drugom nivou.

Faktor D- učestalost i vrijeme trajanja zastoja strojeva i opreme ima izraženo pozitivno djelovanje na zadovoljenost rokova što je lako protumačiti jer se manjim brojem i kraćim trajanjem zastoja strojeva i opreme osigurava veći broj traženih rokova isporuke.

Ovdje još možemo registrirati manji značaj pozitivnog utjecaja faktora A-intenzitet prikupljanja ulaznih informacija, zatim manji negativan utjecaj interakcija BC, CE i CD te mali pozitivan značaj interakcija ABE, ACDE i BCDE.

5.5. Analiza varijance za kriterij U_3

Analiza varijance za rezultate pokusa 2^5 po kriteriju U_3-efikasnost upravljanja zalihama prikazana je u tablici 10. gdje možemo vidjeti malu ukupnu sumu kvadrata odstupanja rezultata pokusa **Σ**Q pri čemu je protumačena suma kvadrata odstupanja **Σ**Qt puno veća od neprotumačenog ostatka, odnosno pogreške Qp pa je i mala varijanca ostatka $(\sigma_o)^2$.

Značajnost utjecajnih faktora i interakcija iz odnosa varijance efekata i varijance ostatka $F_{rač.}$ utvrđena je u slučaju kada je $F_{rač.} > F_{tab.} = 2{,}20$ za vjerojatnost $\alpha = 0{,}01$ za veću vrijednost $F_{rač.}$ pa su izračunima u tablici 10. po rangu utvrđeni sljedeći utjecajni faktori i interakcije:

1. faktor B – oblik plasmana proizvoda, utjecaj +VSSS
2. faktor C - način planiranja i praćenja, utjecaj +VSSS
3. faktor A – intenzitet prikupljanja ulaznih informacija, utjecaj +SSS
4. interakcija ABC, utjecaj +SSS
5. faktor E – učestalost i trajanje zastoja čovjeka, utjecaj +SSS
6. interakcija AC, utjecaj –SS

7. faktor D – učestalost i vrijeme trajanja zastoja strojeva i opreme, utjecaj +SS
8. interakcije BC, utjecaj +S

I ovdje se pojedinačno djelovanje faktora B, C i A na njihovom drugom nivou pokazuje najutjecajnijim prema kriteriju U_3-efikasnost upravljanja zalihama.

Vrijednost pokazatelja U_3 varira po kombinacijama faktora na način da se njegove najveće vrijednosti registriraju kod kombinacija gdje su prisutni A, B i C.

Vidi se da faktor B-oblik plasmana proizvoda najjače i pozitivno djeluje na efikasnost upravljanja zalihama, što je bilo i za očekivati kada se uzme da se 60% kupaca pozna po točno i unaprijed traženim godišnjim i mjesečnim količinama proizvoda. Zato je moguće raditi s manjim količinama proizvoda na zalihama, osnosno maksimalno sa signalnim zalihama, pa se time vrlo izraženo povećava efikasnost upravljanja zalihama.

Utjecajni faktor C-način planiranja i praćenja također ima vrlo jako pozitivno djelovanje na efikasnost upravljanja zalihama. Prema opisanom principu kliznog planiranja i praćenja kao drugog nivo tog faktora intenzivnim periodičkim izmjenama i dopunama promatranih planova i realizacije postiže se veća mogućnost obuhvata aktualnih informacija na tržištu o potrebama kupaca pa se može raditi s manjim zalihama proizvoda i repromaterijala.

I faktor A-intenzitet prikupljanja ulaznih informacija ima jako i pozitivno djelovanje na efikasnost upravljanja zalihama. To je također bilo za očekivati, jer se intenzivnijim prikupljanjem svih relevantnih ulaznih informacija na vrijeme utvrđuju potrebni podaci za operativno planiranje i praćenje te stanje raspoloživih i potrebnih resursa pa se može postići veća efikasnost upravljanja zalihama.

Jako izraženi utjecaj ima i faktor E-učestalost i trajanje zastoja čovjeka jer se manjim brojem izostanak i njhihovim kraćim trajanjem na drugom nivou tretiranja u svim procesima unutar granica objekta istraživanja povećava mogućnost pravovremene nabave repromaterijala te se poboljšavaju elementi pokazatelja efikasnost upravljanja zalihama U_3.

Još se pokazuje jače izraženi negativni utjecaj interakcije AC čemu je vjerojatni uzrok nemogućnost usklade svih parametara tretiranog procesa u datom momentu.

Faktor D- učestalost i vrijeme trajanja zastoja strojeva i opreme ima također nešto jače izraženo pozitivno djelovanje a manji pozitivan utjecaj ima i interakcija BC.

***Tablica 10**. Analiza varijance za kriterij U_3 u pokusima 2^5 x 6*

Pokusi U3		Dobiveni rezultati (Y_{ijklm})Pi u ponavljanjima Pi							Totali kombinacije tretmana									
R.br.	Stanje	P1	P2	P3	P4	P5	P6	**Σ YPi**	Y_i+Y_{i+1} $Y_{i+1}-Y_i$	$(Y_i+Y_{i+1})'$ $(Y_{i+1}-Y_i)'$	$(Y_i+Y_{i+1})''$ $(Y_{i+1}-Y_i)''$	$(Y_i+Y_{i+1})'''$ $(Y_{i+1}-Y_i)'''$	$(Y_i+Y_{i+1})''''$ $(Y_{i+1}-Y_i)''''$	Diviz.	Efekti **E**	Varijanca $(\sigma_E)^2$	**Frač.** = σ_E^2/σ_o^2	Značaj i rang
1		1,058	1,002	1,011	0,984	1,112	1,035	**6,202**	12,543	26,340	55,211	111,949	227,913	192	1,18705			
2	a	1,021	1,135	1,087	1,056	1,038	1,004	**6,341**	13,797	28,871	56,738	115,964	5,413	96	0,05639	0,152607	**76,533**	+SSS (3)
3	b	1,068	1,023	1,094	1,177	1,128	1,078	**6,568**	13,331	26,932	57,642	2,313	12,645	96	0,13172	0,832792	**417,646**	+VSSS (1)
4	ab	1,186	1,243	1,137	1,206	1,162	1,295	**7,229**	15,540	29,806	58,322	3,100	-0,771	96	-0,00803	0,003096	1,553	
5	c	1,035	1,071	1,124	0,994	1,052	1,146	**6,422**	12,777	27,327	1,045	6,333	10,991	96	0,11449	0,629178	**315,533**	+VSSS (2)
6	ac	1,135	1,224	1,084	1,123	1,187	1,156	**6,909**	14,155	30,315	1,268	6,312	-2,349	96	-0,02447	0,028739	**14,412**	-SS (6)
7	bc	1,271	1,382	1,324	1,315	1,341	1,258	**7,891**	14,157	27,862	1,648	-0,491	1,527	96	0,01591	0,012144	**6,090**	+S (8)
8	abc	1,214	1,290	1,246	1,325	1,276	1,298	**7,649**	15,649	30,460	1,452	-0,280	-5,201	96	-0,05418	0,140888	**70,655**	+SSS (4)
9	d	1,010	1,051	1,098	1,042	1,028	1,071	**6,300**	12,958	0,800	3,463	5,405	2,207	96	0,02299	0,025369	**12,723**	+SS (7)
10	ad	1,080	1,045	1,153	1,026	1,106	1,067	**6,477**	14,369	0,245	2,870	5,586	0,027	96	0,00028	0,000004	0,002	
11	bd	1,154	1,087	1,133	1,176	1,043	1,122	**6,715**	14,335	0,902	3,056	-1,091	-0,393	96	-0,00409	0,000804	0,403	
12	abd	1,230	1,173	1,260	1,222	1,302	1,253	**7,440**	15,980	0,366	3,256	-1,258	0,231	96	0,00241	0,000278	0,139	
13	cd	1,063	1,124	1,197	1,102	1,135	1,158	**6,779**	13,173	1,119	-0,207	1,069	-0,047	96	-0,00049	0,000012	0,006	
14	acd	1,170	1,247	1,284	1,225	1,192	1,260	**7,378**	14,689	0,529	-0,284	0,458	-0,059	96	-0,00061	0,000018	0,009	
15	bcd	1,344	1,244	1,315	1,321	1,335	1,382	**7,941**	14,360	1,060	-0,294	-2,631	-0,851	96	-0,00886	0,003772	1,892	
16	abcd	1,309	1,255	1,296	1,275	1,237	1,336	**7,708**	16,100	0,392	0,014	-2,570	-0,067	96	-0,00070	0,000023	0,012	
17	e	1,023	1,117	1,008	1,056	1,045	1,078	**6,327**	0,139	1,254	2,531	1,527	4,015	96	0,04182	0,083960	**42,106**	+SSS (5)
18	ae	1,080	1,107	1,100	1,123	1,191	1,030	**6,631**	0,661	2,209	2,874	0,680	0,787	96	0,00820	0,003226	1,618	
19	be	1,105	1,115	1,140	1,132	1,074	1,211	**6,777**	0,487	1,378	2,988	0,223	-0,021	96	-0,00022	0,000002	0,001	
20	abe	1,331	1,223	1,266	1,273	1,198	1,301	**7,592**	-0,242	1,492	2,598	-0,196	0,211	96	0,00220	0,000232	0,116	
21	ce	1,115	1,132	1,140	1,168	1,088	1,191	**6,834**	0,177	1,411	-0,555	-0,593	0,181	96	0,00189	0,000171	0,086	
22	ace	1,267	1,214	1,241	1,284	1,235	1,260	**7,501**	0,725	1,645	-0,536	0,200	-0,167	96	-0,00174	0,000145	0,073	
23	bce	1,312	1,345	1,359	1,283	1,385	1,375	**8,059**	0,599	1,516	-0,590	-0,077	-0,611	96	-0,00636	0,001944	0,975	
24	abce	1,317	1,287	1,388	1,344	1,320	1,265	**7,921**	-0,233	1,740	-0,668	0,308	0,061	96	0,00064	0,000019	0,010	
25	de	1,055	1,024	1,075	1,082	1,095	1,149	**6,480**	0,304	0,522	0,955	0,343	-0,847	96	-0,00882	0,003737	1,874	
26	ade	1,090	1,076	1,115	1,120	1,179	1,113	**6,693**	0,815	-0,729	0,114	-0,390	-0,419	96	-0,00436	0,000914	0,459	
27	bde	1,187	1,154	1,215	1,080	1,115	1,170	**6,921**	0,667	0,548	0,234	0,019	0,793	96	0,00826	0,003275	1,643	
28	abde	1,382	1,294	1,267	1,320	1,292	1,213	**7,768**	-0,138	-0,832	0,224	-0,078	0,385	96	0,00401	0,000772	0,387	
29	cde	1,156	1,084	1,172	1,201	1,134	1,180	**6,927**	0,213	0,511	-1,251	-0,841	-0,733	96	-0,00764	0,002798	1,403	
30	acde	1,187	1,220	1,258	1,286	1,215	1,267	**7,433**	0,847	-0,805	-1,380	-0,010	-0,097	96	-0,00101	0,000049	0,025	
31	bcde	1,302	1,382	1,354	1,336	1,370	1,363	**8,107**	0,506	0,634	-1,316	-0,129	0,831	96	0,00866	0,003597	1,804	
32	abcde	1,368	1,267	1,353	1,344	1,269	1,392	**7,993**	-0,114	-0,620	-1,254	0,062	0,191	96	0,00199	0,000190	0,095	
	Σ Y²	**44,649**	**44,622**	**46,176**	**45,522**	**45,183**	**46,645**											
							Σ Y	**227,913**										

Ukupna suma kvadrata odstupanja Σ Q = Σ Y² - (Σ Y)² =	**2,253797**
Korigirana, protumačena suma kvadrata odstupanja Σ Qt =	**1,934754**
Neprotumačeni ostatak - pogreška Qp = Σ Q - Σ Qt =	**0,319042**

Stupanj slobode glavnih efekata interakcije, s n = 5 faktora, Sst = 2^n - 1 =	**31**
Stupanj slobode ukupni, s r = 6 ponavljanja, Ssu = (2^n x r) - 1 =	**191**
Stupanj slobode ostatka - pogreške, Ssp = Ssu - Sst =	**160**
Varijanca ostatka $(\sigma_o)^2$ = Qp / Ssp =	**0,001994**
Kritična tab. vrijednost Ftab kod F -raspodjele za prag značajnosti α= 0,01	**2,20**

5.6. Analiza varijance za sintetski kriterij U

Analiza varijance za rezultate pokusa 2^5 po sintetskom kriteriju U – uspješnost planiranja i praćenja prikazana je u tablici 11. gdje možemo vidjeti primjetnu veću ukupnu sumu kvadrata odstupanja rezultata pokusa **Σ**Q jer su rasponi dobivenih rezultata pokusa znatno veći od onih po pojedinačnim kriterijima. Pri tomu je protumačena suma kvadrata odstupanja **Σ**Qt puno veća od neprotumačenog ostatka, odnosno pogreške Qp pa je i varijanca ostatka $(\sigma_o)^2$ još manja.

Iz odnosa varijance efekata i varijance ostatka $F_{rač.}$ utvrđena je značajnost utjecajnih faktora i interakcija kada im je $F_{rač.} > F_{tab.} = 2{,}20$ za vjerojatnost $\alpha = 0{,}01$ za veću vrijednost $F_{rač.}$ pa su izračunima u tablici 11. po rangu utvrđeni sljedeći utjecajni faktori i interakcije:

1. faktor C - način planiranja i praćenja, utjecaj +VSSS
2. faktor B – oblik plasmana proizvoda, utjecaj +VSSS
3. faktor E – učestalost i trajanje zastoja čovjeka, utjecaj +SSS
4. faktor A – intenzitet prikupljanja ulaznih informacija, utjecaj +VSSS
5. interakcija ABC, utjecaj –VSSS
6. faktor D – učestalost i vrijeme trajanja zastoja strojeva i opreme, utjecaj +SS
7. interakcija AB, utjecaj –SS

Pored navedenog, još je zabilježen mali značaj interakcija AC, BC, BCD, DE i BCDE.

I prema ovom sintetskom kriteriju se pojedinačno djelovanje faktora B, C i E na njihovom drugom nivou pokazuje najutjecajnijim, a posebno je izračen utjecaj faktora C, dok je utjecaj interakcija jako mali.

Sintetski pokazatelj uspješnosti planiranja i praćenja najveći je za kombinacije faktora B i C samostalno ili uz dodatak faktora D i E.

Utjecajni faktor C-način planiranja i praćenja ima najjače pozitivno djelovanje na uspješnost planiranja i praćenja proizvodnje. Prema opisanom principu kliznog planiranja i praćenja kao drugog nivo tog faktora intenzivnim periodičkim izmjenama i dopunama promatranih planova i realizacije postiže se veća mogućnost obuhvata aktualnih informacija na tržištu o potrebama kupaca i ostalim potrebnim ulaznim informacijama.

I ovdje je glavni razlog za vrlo jako djelovanje ovog faktora u tome što je model oponašanja za slučaj kada je faktor C na drugom nivou, odnosno kada se koristi klizno planiranje i praćenje, nešto drugačiji model oponašanja pa se samim time dodatno potencira njegov utjecaj.

***Tablica 11**. Analiza varijance za kriterij **U** u pokusima **2^5** x 6*

Pokusi U		Dobiveni rezultati (Y_{ijklm})P_i u ponavljanjima Pi							Totali kombinacije tretmana									
R.br.	Stanje	P1	P2	P3	P4	P5	P6	**Σ Y_{Pi}**	Y_i+Y_{i+1} $Y_{i+1}-Y_i$	$(Y_i+Y_{i+1})'$ $(Y_{i+1}-Y_i)'$	$(Y_i+Y_{i+1})''$ $(Y_{i+1}-Y_i)''$	$(Y_i+Y_{i+1})'''$ $(Y_{i+1}-Y_i)'''$	$(Y_i+Y_{i+1})''''$ $(Y_{i+1}-Y_i)''''$	Diviz	Efekti **E**	Varijanca $(\sigma_E)^2$	**Frač.** = σ_E^2/σ_o^2	Značaj i rang
1		0,611	0,622	0,629	0,588	0,664	0,613	**3,727**	7,608	16,328	35,668	73,349	153,456	192	0,79925			
2	a	0,671	0,700	0,679	0,625	0,599	0,607	**3,881**	8,720	19,340	37,681	80,107	6,118	96	0,06373	0,194948	**154,166**	+VSSS (4)
3	b	0,667	0,653	0,644	0,709	0,740	0,663	**4,076**	8,913	17,289	39,567	3,085	9,854	96	0,10265	0,505736	**399,940**	+VSSS (2)
4	ab	0,776	0,812	0,704	0,745	0,760	0,847	**4,644**	10,427	20,392	40,540	3,033	-2,092	96	-0,02179	0,022794	**18,026**	-SS (7)
5	c	0,657	0,645	0,707	0,626	0,633	0,727	**3,995**	7,936	18,204	1,448	4,907	11,822	96	0,12315	0,727915	**575,640**	+VSSS (1)
6	ac	0,795	0,858	0,786	0,815	0,853	0,811	**4,918**	9,353	21,363	1,637	4,947	-0,844	96	-0,00879	0,003710	**2,934**	-S (11)
7	bc	0,862	0,920	0,891	0,883	0,891	0,865	**5,312**	9,764	18,996	1,685	-1,365	-0,776	96	-0,00808	0,003136	**2,480**	-S (12)
8	abc	0,781	0,889	0,836	0,889	0,881	0,839	**5,115**	10,628	21,544	1,348	-0,727	-6,026	96	-0,06277	0,189129	**149,564**	-VSSS (5)
9	d	0,592	0,672	0,702	0,622	0,612	0,626	**3,826**	8,380	0,722	2,626	6,115	2,986	96	0,03110	0,046439	**36,724**	+SSS (6)
10	ad	0,653	0,672	0,743	0,686	0,711	0,645	**4,110**	9,824	0,726	2,281	5,707	-0,148	96	-0,00154	0,000114	0,090	
11	bd	0,732	0,742	0,719	0,770	0,648	0,735	**4,346**	10,118	0,945	2,571	-0,249	-0,540	96	-0,00563	0,001519	1,201	
12	abd	0,842	0,790	0,833	0,807	0,877	0,858	**5,007**	11,245	0,692	2,376	-0,595	0,710	96	0,00740	0,002626	2,076	
13	cd	0,716	0,716	0,811	0,702	0,744	0,761	**4,450**	8,827	0,954	-0,706	-0,151	-0,520	96	-0,00542	0,001408	1,114	
14	acd	0,809	0,932	0,925	0,857	0,898	0,893	**5,314**	10,169	0,731	-0,659	-0,625	-0,406	96	-0,00423	0,000859	0,679	
15	bcd	0,899	0,888	0,880	0,904	0,899	0,930	**5,400**	10,255	0,860	-0,695	-2,947	-0,946	96	-0,00985	0,004661	**3,686**	-S (10)
16	abcd	0,875	0,817	0,925	0,912	0,806	0,893	**5,228**	11,289	0,488	-0,032	-3,079	-0,008	96	-0,00008	0,000000	0,000	
17	e	0,649	0,692	0,655	0,708	0,665	0,680	**4,049**	0,154	1,112	3,012	2,013	6,758	96	0,07040	0,237868	**188,107**	+VSSS (3)
18	ae	0,699	0,724	0,725	0,726	0,778	0,679	**4,331**	0,568	1,514	3,103	0,973	-0,052	96	-0,00054	0,000014	0,011	
19	be	0,737	0,766	0,767	0,755	0,736	0,815	**4,576**	0,923	1,417	3,159	0,189	0,040	96	0,00042	0,000008	0,007	
20	abe	0,940	0,833	0,869	0,873	0,815	0,918	**5,248**	-0,197	0,864	2,548	-0,337	0,638	96	0,00665	0,002120	1,677	
21	ce	0,760	0,770	0,753	0,797	0,738	0,787	**4,605**	0,284	1,444	0,004	-0,345	-0,408	96	-0,00425	0,000867	0,686	
22	ace	0,913	0,908	0,915	0,945	0,925	0,907	**5,513**	0,661	1,127	-0,253	-0,195	-0,346	96	-0,00360	0,000624	0,493	
23	bce	0,921	0,922	0,966	0,909	0,955	1,038	**5,711**	0,864	1,342	-0,223	0,047	-0,474	96	-0,00494	0,001170	0,925	
24	abce	0,909	0,890	0,984	0,952	0,925	0,874	**5,534**	-0,172	1,034	-0,372	0,663	-0,132	96	-0,00137	0,000091	0,072	
25	de	0,715	0,685	0,741	0,743	0,732	0,779	**4,395**	0,282	0,414	0,402	0,091	-1,040	96	-0,01083	0,005633	**4,455**	-S (8)
26	ade	0,727	0,723	0,724	0,745	0,792	0,721	**4,432**	0,672	-1,120	-0,553	-0,611	-0,526	96	-0,00548	0,001441	1,140	
27	bde	0,781	0,800	0,809	0,754	0,731	0,798	**4,673**	0,908	0,377	-0,317	-0,257	0,150	96	0,00156	0,000117	0,093	
28	abde	0,971	0,908	0,912	0,928	0,905	0,872	**5,496**	-0,177	-1,036	-0,308	-0,149	0,616	96	0,00642	0,001976	1,563	
29	cde	0,824	0,748	0,793	0,857	0,780	0,799	**4,801**	0,037	0,390	-1,534	-0,955	-0,702	96	-0,00731	0,002567	2,030	
30	acde	0,854	0,909	0,930	0,952	0,900	0,909	**5,454**	0,823	-1,085	-1,413	0,009	0,108	96	0,00112	0,000061	0,048	
31	bcde	0,901	0,950	0,990	0,965	0,955	0,966	**5,727**	0,653	0,786	-1,475	0,121	0,964	96	0,01004	0,004840	**3,828**	+S (9)
32	abcde	0,939	0,897	0,942	0,934	0,896	0,954	**5,562**	-0,165	-0,818	-1,604	-0,129	-0,250	96	-0,00260	0,000326	0,257	
	Σ Y^2	**20,167**	**20,559**	**21,301**	**21,000**	**20,581**	**21,208**											
							Σ Y	**153,456**										

Ukupna suma kvadrata odstupanja Σ Q = Σ Y^2 - (Σ Y)^2 =	**2,167040**
Korigirana, protumačena suma kvadrata odstupanja Σ Qt =	**1,964715**
Neprotumačeni ostatak - pogreška Qp = Σ Q - Σ Qt =	**0,202325**

Stupanj slobode glavnih efekata interakcije, s n = 5 faktora, Sst = 2^n - 1 =	**31**
Stupanj slobode ukupni, s r = 6 ponavljanja, Ssu = (2^n x r) - 1 =	**191**
Stupanj slobode ostatka - pogreške, Ssp = Ssu - Sst =	**160**
Varijanca ostatka $(\sigma_o)^2$ = Qp / Ssp =	**0,001265**
Kritična tab. vrijednost Ftab kod F -raspodjele za prag značajnosti α= 0,01	**2,200**

Faktor B-oblik plasmana proizvoda ima vrlo jako pozitivno djelovanje na uspješnost planiranja i praćenja, što je i logično kada se uzme u obzir da se na drugom nivou tog faktora oko 60% kupaca pozna po točno i unaprijed traženim godišnjim i mjesečnim količinama proizvoda. Tada imamo više pouzdanih ulaznih informacija za izradu planova, poznat je veći dio količina i rokova isporuka po zahtjevima kupaca, a moguće je raditi s manjim količinama proizvoda na zalihama, odnosno maksimalno sa signalnim zalihama. Time se vrlo jako poboljšavaju svi pojedinačni i sintetski pokazatelji uspješnosti planiranja i praćenja.

Vrlo jako izraženi utjecaj ima i faktor E-učestalost i trajanje zastoja čovjeka jer se manjim brojem izostanak i njihovim kraćim trajanjem na drugom nivou tretiranja u svim procesima unutar granica objekta istraživanja povećava mogućnost izrade preciznijih planova i veća realizacija proizvodnje i otpreme, bolje poštivanje rokova proizvodnje i otpreme proizvoda te pravovremene nabave repromaterijala čime se također poboljšavaju svi pokazatelji uspješnosti planiranja i praćenja.

Interakcija ABC ima također vrlo jaki ali negativan utjecaj što se može obrazložiti promjenama u realizaciji kada se kliznim planiranjem i praćenjem, faktor C na drugom nivou, temeljem većeg broja ulaznih informacija mijenjaju parametri planiranja i realizacije proizvodnje - narudžbi već poznatih kupaca, tj. kada su i faktori A i B na drugom nivou.

Utjecajni faktor A-intenzitet prikupljanja ulaznih informacija ima i po ovom sintetskom kriteriju uspješnosti planiranja i praćenja vrlo jako pozitivno djelovanje, a što je također bilo za očekivati. Intenzivnijim prikupljanjem svih relevantnih ulaznih informacija na vrijeme se utvrđuju potrebni podaci za operativno planiranje i praćenje te stanje raspoloživih i potrebnih resursa. Zato se može postići veća uspješnost planiranja i praćenja, odnosno bolji rezultati planiranja i praćenja po svim odabranim kriterijima.

I faktor D se pokazuje s izraženim pozitivnim utjecajem kao što se manje ili više pokazao pozitivno utjecajan i po svakom od pojedinačnih kriterija uspješnosti.

Kao izraženo značajna s negativnim djelovanjem pokazuje se još i interakcija AB što se može tumačiti promjenama u planiranju i realizaciji kod većeg broja novih ulaznih informacija, tj. kada je faktor A na drugom nivou, a kada se realiziraju prethodno definirani planovi i proizvodnja većinom za poznatog kupca, odnosno s faktorom B na drugom nivou.

Registrirani manji utjecaji interakcija AC, BC, BCD, DE, i BCDE nema jasnih logičnih objašnjenja pa ih se definitivno može smatrati pogreškom modela oponašanja.

Ovdje su napravljene još dvije grupe pokusa 2^4 po dobivenim rezultatima prema kriteriju U–uspješnost planiranja i praćenja zbog boljeg uvida u djelovanje utjecajnih faktora, i to:

1. Pokusi U_b – izostavljen je faktor B-oblik plasmana proizvoda, tablica 12.
2. Pokusi U_c – izostavljen je faktor C-način planiranja i praćenja, tablica 13.

Pri analizi varijance za pokuse 2^4 po svakom od korištenih kriterija značajnost svakog od utjecajnih faktora i interakcija određena je prema njihovoj vrijednosti $F_{rač.}=(\sigma_E)^2/(\sigma_o)^2$ u odnosu na kritičnu tabelarnu vrijednosti $\mathbf{F_{tab.}}$= 3,00 kod **F**-raspodjele za vjerojatnost α=0,01 za veću vrijednost $F_{rač.}$, uz stupanj slobode glavnih efekata i interakcija 15 i stupanj slobode ostatka-pogrešaka S_{sp}=80 koji su izračunati po izrazima (22), (23) i (24) uz n=4.

Izostavljanjem faktora B iz tretiranja vidljiv je i dalje vrlo izraženi utjecaj faktora C, još jače djelovanje faktora A, vrlo velik utjecaj faktora E te jaki utjecaj interakcije AC i izraženi utjecaj faktora D.

I po ovom kriteriju se vidi da je utjecaj interakcije AC pozitivan kada god se ne radi o varijanti plasmana za većinom poznate kupce, odnosno kada se radi za zalihe.

Izostavljanjem faktora C iz tretiranja vidljiv je vrlo jaki značaj faktora B i faktora E, a interakcija AB se ovdje pokazuje s jakim pozitivnim djelovanjem, za razliku od plana pokusa 2^5, a što još jednom dokazuje da su faktori A i C te A i B u interaktivnom djelovanju pozitivni dok se njihova interakcija ABC pokazuje negativnim.

To potvrđuje da je korisno imati veći broj ulaznih informacija kod kliznog planiranja i praćenja za slučaj proizvodnje za zalihe kao i kod većinske proizvodnje za poznatog kupca, ali kada nema kliznog planiranja i praćenja.

Tablica 12. *Analiza varijance za kriterij* ***U*** *u pokusima* 2^4 *x 6, bez faktora* ***B***

Pokusi U_b		Dobiveni rezultati $(Y_{ijklm})_{Pi}$ u ponavljanjima Pi							Totali kombinacije tretmana					Efekti	Varijanca	$F_{rač.}$ =	Značaj i rang
R.br.	Stanje	P1	P2	P3	P4	P5	P6	ΣY_{pi}	Y_i+Y_{i+1} / $Y_{i+1}-Y_i$	$(Y_i+Y_{i+1})'$ / $(Y_{i+1}-Y_i)'$	$(Y_i+Y_{i+1})''$ / $(Y_{i+1}-Y_i)''$	$(Y_i+Y_{i+1})'''$ / $(Y_{i+1}-Y_i)'''$	Diviz	E	$(\sigma_E)^2$	σ_E^2/σ_o^2	
1		0,611	0,622	0,629	0,588	0,664	0,613	**3,727**	7,608	16,521	34,221	71,801	96	0,74793			
2	a	0,671	0,700	0,679	0,625	0,599	0,607	**3,881**	8,913	17,700	37,580	4,105	48	0,08552	0,175532	**153,354**	+VSSS (2)
3	c	0,657	0,645	0,707	0,626	0,633	0,727	**3,995**	7,936	18,498	2,225	6,299	48	0,13123	0,413306	**361,086**	+VSSS (1)
4	ac	0,795	0,858	0,786	0,815	0,853	0,811	**4,918**	9,764	19,082	1,880	2,591	48	0,05398	0,069930	**61,095**	+SSS (4)
5	d	0,592	0,672	0,702	0,622	0,612	0,626	**3,826**	8,380	1,077	3,133	1,763	48	0,03673	0,032377	**28,286**	+SS (5)
6	ad	0,653	0,672	0,743	0,686	0,711	0,645	**4,110**	10,118	1,148	3,166	-0,429	48	-0,00894	0,001917	1,675	
7	cd	0,716	0,716	0,811	0,702	0,744	0,761	**4,450**	8,827	1,190	1,349	0,213	48	0,00444	0,000473	0,413	
8	acd	0,809	0,932	0,925	0,857	0,898	0,893	**5,314**	10,255	0,690	1,242	-0,199	48	-0,00415	0,000413	0,360	
9	e	0,649	0,692	0,655	0,708	0,665	0,680	**4,049**	0,154	1,305	1,179	3,359	48	0,06998	0,117530	**102,680**	+VSSS (3)
10	ae	0,699	0,724	0,725	0,726	0,778	0,679	**4,331**	0,923	1,828	0,584	-0,345	48	-0,00719	0,001240	1,083	
11	ce	0,760	0,770	0,753	0,797	0,738	0,787	**4,605**	0,284	1,738	0,071	0,033	48	0,00069	0,000011	0,010	
12	ace	0,913	0,908	0,915	0,945	0,925	0,907	**5,513**	0,864	1,428	-0,500	-0,107	48	-0,00223	0,000119	0,104	
13	de	0,715	0,685	0,741	0,743	0,732	0,779	**4,395**	0,282	0,769	0,523	-0,595	48	-0,01240	0,003688	**3,222**	-S (7)
14	ade	0,727	0,723	0,724	0,745	0,792	0,721	**4,432**	0,908	0,580	-0,310	-0,571	48	-0,01190	0,003396	**2,967**	-S (8)
15	cde	0,824	0,748	0,793	0,857	0,780	0,799	**4,801**	0,037	0,626	-0,189	-0,833	48	-0,01735	0,007228	**6,315**	-S (6)
16	acde	0,854	0,909	0,930	0,952	0,900	0,909	**5,454**	0,653	0,616	-0,010	0,179	48	0,00373	0,000334	0,292	
	ΣY^2	**8,600**	**9,112**	**9,458**	**9,182**	**9,197**	**9,072**										
							ΣY	**71,801**									

Ukupna suma kvadrata odstupanja $\Sigma Q = \Sigma Y^2 - (\Sigma Y)^2$ =	**0,919062**
Korigirana, protumačena suma kvadrata odstupanja ΣQt =	**0,827493**
Neprotumačeni ostatak - pogreška $Qp = \Sigma Q - \Sigma Qt$ =	**0,091569**

Stupanj slobode glavnih efekata interakcije, s n = 5 faktora, Sst = 2^n - 1 =	**15**
Stupanj slobode ukupni, s r = 6 ponavljanja, Ssu = (2^n x r) - 1 =	**95**
Stupanj slobode ostatka - pogreške, Ssp = Ssu - Sst =	**80**
Varijanca ostatka $(\sigma_o)^2$ = Qp / Ssp =	**0,001145**
Kritična tab. vrijednost Ftab kod F -raspodjele za prag značajnosti α= 0,01	**3,000**

Tablica 13. *Analiza varijance za kriterij* ***U*** *u pokusima* 2^4 *x 6, bez faktora* ***C***

Pokusi U_c		Dobiveni rezultati (Y_{ijklm})Pi u ponavljanjima Pi							Totali kombinacije tretmana					Efekti	Varijanca	$F_{rač.}$ =	Značaj
R.br	Stanje	P1	P2	P3	P4	P5	P6	**Σ Y_{Pi}**	Y_i+Y_{i+1} $Y_{i+1}-Y_i$	$(Y_i+Y_{i+1})'$ $(Y_{i+1}-Y_i)'$	$(Y_i+Y_{i+1})''$ $(Y_{i+1}-Y_i)''$	$(Y_i+Y_{i+1})'''$ $(Y_{i+1}-Y_i)'''$	Diviz	**E**	$(\sigma_E)^2$	σ_E^2/σ_o^2	i rang
1		0,611	0,622	0,629	0,588	0,664	0,613	**3,727**	7,608	16,328	33,617	70,817	96	0,73768			
2	a	0,671	0,700	0,679	0,625	0,599	0,607	**3,881**	8,720	17,289	37,200	3,481	48	0,07252	0,126223	**98,139**	+SSS (3)
3	b	0,667	0,653	0,644	0,709	0,740	0,663	**4,076**	7,936	18,204	1,667	5,315	48	0,11073	0,294263	**228,791**	+VSSS (1)
4	ab	0,776	0,812	0,704	0,745	0,760	0,847	**4,644**	9,353	18,996	1,814	1,967	48	0,04098	0,040303	**31,336**	+SSS (4)
5	d	0,592	0,672	0,702	0,622	0,612	0,626	**3,826**	8,380	0,722	2,529	1,753	48	0,03652	0,032011	**24,888**	+SS (5)
6	ad	0,653	0,672	0,743	0,686	0,711	0,645	**4,110**	9,824	0,945	2,786	0,129	48	0,00269	0,000173	0,135	
7	bd	0,732	0,742	0,719	0,770	0,648	0,735	**4,346**	8,827	0,954	0,791	0,203	48	0,00423	0,000429	0,334	
8	abd	0,842	0,790	0,833	0,807	0,877	0,858	**5,007**	10,169	0,860	1,176	0,359	48	0,00748	0,001343	1,044	
9	e	0,649	0,692	0,655	0,708	0,665	0,680	**4,049**	0,154	1,112	0,961	3,583	48	0,07465	0,133728	**103,974**	+VSSS (2)
10	ae	0,699	0,724	0,725	0,726	0,778	0,679	**4,331**	0,568	1,417	0,792	0,147	48	0,00306	0,000225	0,175	
11	be	0,737	0,766	0,767	0,755	0,736	0,815	**4,576**	0,284	1,444	0,223	0,257	48	0,00535	0,000688	0,535	
12	abe	0,940	0,833	0,869	0,873	0,815	0,918	**5,248**	0,661	1,342	-0,094	0,385	48	0,00802	0,001544	1,200	
13	de	0,715	0,685	0,741	0,743	0,732	0,779	**4,395**	0,282	0,414	0,305	-0,169	48	-0,00352	0,000298	0,231	
14	ade	0,727	0,723	0,724	0,745	0,792	0,721	**4,432**	0,672	0,377	-0,102	-0,317	48	-0,00660	0,001047	0,814	
15	bde	0,781	0,800	0,809	0,754	0,731	0,798	**4,673**	0,037	0,390	-0,037	-0,407	48	-0,00848	0,001726	1,342	
16	abde	0,971	0,908	0,912	0,928	0,905	0,872	**5,496**	0,823	0,786	0,396	0,433	48	0,00902	0,001953	1,518	
	Σ Y^2	**8,821**	**8,781**	**8,880**	**8,793**	**8,764**	**8,940**										
							Σ Y	**70,817**									

Ukupna suma kvadrata odstupanja Σ Q = Σ Y^2 - (Σ Y)² =	**0,738845**
Korigirana, protumačena suma kvadrata odstupanja Σ Qt =	**0,635952**
Neprotumačeni ostatak - pogreška Qp = Σ Q - Σ Qt =	**0,102893**

Stupanj slobode glavnih efekata interakcije, s n = 5 faktora, Sst = 2^n - 1 =	**15**
Stupanj slobode ukupni, s r = 6 ponavljanja, Ssu = (2^n x r) - 1 =	**95**
Stupanj slobode ostatka - pogreške, Ssp = Ssu - Ssu =	**80**
Varijanca ostatka $(\sigma_o)^2$ = Qp / Ssp =	**0,001286**
Kritična tab. vrijednost Ftab kod F -raspodjele za prag značajnosti α= 0,01	**3,000**

5.7. Dodatna analiza varijance

Da bi se napravila zaključna analiza dobivenih rezultata na konkretnom, praktičnom primjeru i eventualno poopćili dobiveni rezultati, napravljena je dodatna analiza varijance za dva posebna praktična primjera, i to:

1. Slučaj kada je razlika nivoa faktora manja
2. Slučaj kada je povećano učešće proizvodnje za poznatog kupca

Naime, na taj se način želi provjeriti da li izvor i starost podataka korištenih u istraživanju na modelu ima većeg značaja na dobivene rezultate i zaključke koji se mogu poopćiti.

U tablici 14. napravljena je analiza varijance za pretpostavljeni slučaj smanjene razlike nivoa faktora u odnosu na obrađivani praktični primjer kao slučaj kada okolnosti i okruženje ne dozvoljavaju veće promjene kod utjecajnih faktora, odnosno njihovog 2. nivoa. Pri tomu je samo faktor C – način planiranja i praćenja imao isti drugi nivo, odnosno korišteno je identično klizno planiranje i praćenje kao i prethodno.

Dobiveni rezultati i dalje pokazuju najznačajniji utjecaj faktora C - način planiranja i praćenja, odnosno kliznog planiranja i praćenja kao 2. nivoa tog faktora, na uspješnost tog procesa. Bitna razlika u odnosu na početni praktični primjer, čija je analiza varijance prikazana u tablici 11. na stranici 102, je osjetno smanjenje pozitivnog utjecaja faktora A- intenzitet prikupljanja informacija i negativni utjecaj interakcije ABC. To je bilo i za očekivati jer uz manje povećanje intenziteta prikupljanja podataka i manje povećanje broja poznatih kupaca biti će manje promjene u operativnim planovima proizvodnje.

U drugom slučaju, prikazanom u tablici 15., kada je povećana razlika nivoa faktora B – način plasmana na način da je pretpostavljeno veće učešće prodaje za poznatog kupca, tj. po narudžbi, faktor B je pokazao veći utjecaj od faktora C – način planiranja i praćenja a što je bilo i za očekivati. No, utjecaj faktora C, odnosno kliznog planiranja i praćenja, i dalje je velik i osjetno jači u odnosu na ostale tretirane faktora.

I ovaj mali test pokazuje da klizno planiranje i praćenje proizvodnje ima znatan utjecaj na njenu uspješnost i u slučaju proizvodnje za poznatog kupca jer se takvim planiranjem i praćenjem usklađuju planovi i realizacija ne samo s aspekta promjena na tržištu plasmana već se to čini i za slučajeve kada dolazi do poremećaja u proizvodnji i dobavi repromaterijala.

Bez obzira na činjenicu da će efekti kliznog planiranja i praćenja i sama uspješnost proizvodnje biti veći ako se radi o proizvodnji za kombinirani plasman – sa zaliha i za poznate kupce, ne bi se smjelo nastavak istraživanja ograničiti samo na neke tipove i vrste proizvodnje.

***Tablica 14**. Analiza varijance za kriterij **U** u pokusima **2^5** x 6 sa smanjenom razlikom nivoa faktora*

Pokusi U		Dobiveni rezultati (Y_{ijklm})P_i u ponavljanjima Pi							Totali kombinacije tretmana						Efekti	Varijanca	**Frač.** =	Značaj
									Y_i+Y_{i+1}	$(Y_i+Y_{i+1})'$	$(Y_i+Y_{i+1})''$	$(Y_i+Y_{i+1})'''$	$(Y_i+Y_{i+1})''''$					
R.br.	Stanje	P1	P2	P3	P4	P5	P6	**Σ YPi**	$Y_{i+1}-Y_i$	$(Y_{i+1}-Y_i)'$	$(Y_{i+1}-Y_i)''$	$(Y_{i+1}-Y_i)'''$	$(Y_{i+1}-Y_i)''''$	Div.	**E**	$(\sigma_E)^2$	σ_E^2/σ_o^2	i rang
1		0,611	0,637	0,613	0,592	0,663	0,613	**3,729**	7,500	15,940	34,068	69,689	144,429	192	0,75223			
2	a	0,639	0,680	0,659	0,606	0,593	0,594	**3,771**	8,440	18,128	35,621	74,740	3,633	96	0,03785	0,068751	**58,341**	+SSS (4)
3	b	0,678	0,653	0,645	0,717	0,742	0,673	**4,108**	8,605	16,448	36,918	1,929	7,823	96	0,08149	0,318730	**270,470**	+VSSS (2)
4	ab	0,726	0,755	0,675	0,700	0,688	0,788	**4,332**	9,523	19,173	37,822	1,704	-1,365	96	-0,01422	0,009701	**8,233**	-S (7)
5	c	0,657	0,645	0,707	0,627	0,633	0,727	**3,996**	7,643	17,263	0,878	3,729	9,455	96	0,09849	0,465590	**395,093**	+VSSS (1)
6	ac	0,745	0,794	0,737	0,764	0,800	0,769	**4,609**	8,805	19,655	1,051	4,094	0,803	96	0,00837	0,003360	**2,851**	-S (11)
7	bc	0,771	0,829	0,799	0,791	0,813	0,759	**4,762**	9,232	17,836	1,084	-0,743	-1,063	96	-0,01108	0,005887	**4,996**	-S (8)
8	abc	0,713	0,830	0,778	0,842	0,816	0,782	**4,761**	9,941	19,986	0,620	-0,622	-2,211	96	-0,02303	0,025456	**21,602**	-SSS (6)
9	d	0,587	0,650	0,679	0,609	0,600	0,621	**3,746**	8,035	0,266	1,858	4,913	2,457	96	0,02560	0,031447	**26,686**	+SSS (5)
10	ad	0,628	0,639	0,695	0,641	0,677	0,617	**3,897**	9,228	0,612	1,871	4,542	-0,291	96	-0,00303	0,000442	0,375	
11	bd	0,723	0,730	0,710	0,774	0,634	0,727	**4,298**	9,251	0,360	2,346	0,677	-0,585	96	-0,00609	0,001781	1,512	
12	abd	0,750	0,697	0,759	0,734	0,804	0,763	**4,507**	10,404	0,691	1,748	0,126	-0,037	96	-0,00039	0,000007	0,006	
13	cd	0,697	0,701	0,789	0,691	0,728	0,745	**4,351**	8,344	0,465	-0,432	-0,475	0,295	96	0,00307	0,000454	0,385	
14	acd	0,727	0,857	0,865	0,791	0,820	0,821	**4,881**	9,492	0,619	-0,311	-0,588	-0,197	96	-0,00205	0,000203	0,172	
15	bcd	0,828	0,783	0,796	0,819	0,814	0,850	**4,890**	9,693	0,324	-0,232	-1,223	-0,939	96	-0,00978	0,004590	**3,895**	-S (9)
16	abcd	0,858	0,799	0,884	0,877	0,770	0,863	**5,051**	10,293	0,296	-0,390	-0,988	-0,175	96	-0,00182	0,000160	0,136	
17	e	0,625	0,674	0,627	0,678	0,641	0,655	**3,900**	0,042	0,940	2,188	1,553	5,051	96	0,05262	0,132889	**112,767**	+VSSS (3)
18	ae	0,671	0,689	0,692	0,693	0,741	0,649	**4,135**	0,224	0,918	2,725	0,904	-0,225	96	-0,00235	0,000264	0,224	
19	be	0,724	0,749	0,754	0,747	0,726	0,799	**4,499**	0,613	1,162	2,392	0,173	0,365	96	0,00380	0,000695	0,589	
20	abe	0,852	0,759	0,783	0,787	0,729	0,819	**4,729**	-0,001	0,709	2,150	-0,464	0,121	96	0,00126	0,000076	0,064	
21	ce	0,728	0,738	0,722	0,764	0,707	0,755	**4,414**	0,151	1,193	0,346	0,013	-0,371	96	-0,00386	0,000716	0,608	
22	ace	0,802	0,795	0,802	0,831	0,811	0,796	**4,837**	0,209	1,153	0,331	-0,598	-0,551	96	-0,00574	0,001582	1,343	
23	bce	0,827	0,840	0,869	0,799	0,879	0,890	**5,104**	0,530	1,148	0,154	0,121	-0,113	96	-0,00118	0,000066	0,056	
24	abce	0,882	0,870	0,879	0,926	0,908	0,835	**5,300**	0,161	0,600	-0,028	-0,158	0,235	96	0,00245	0,000287	0,244	
25	de	0,673	0,649	0,697	0,691	0,695	0,733	**4,138**	0,235	0,182	-0,022	0,537	-0,649	96	-0,00676	0,002195	1,863	
26	ade	0,691	0,686	0,691	0,707	0,747	0,684	**4,206**	0,230	-0,614	-0,453	-0,242	-0,637	96	-0,00663	0,002112	1,792	
27	bde	0,774	0,785	0,809	0,729	0,722	0,799	**4,618**	0,423	0,058	-0,040	-0,015	-0,611	96	-0,00637	0,001946	1,651	
28	abde	0,864	0,805	0,809	0,823	0,802	0,771	**4,874**	0,196	-0,369	-0,548	-0,182	-0,279	96	-0,00290	0,000405	0,344	
29	cde	0,795	0,721	0,764	0,826	0,752	0,770	**4,628**	0,068	-0,005	-0,796	-0,431	-0,779	96	-0,00812	0,003162	**2,683**	- S (12)
30	acde	0,778	0,844	0,864	0,899	0,826	0,854	**5,065**	0,256	-0,227	-0,427	-0,508	-0,167	96	-0,00174	0,000145	0,123	
31	bcde	0,805	0,891	0,891	0,879	0,870	0,881	**5,217**	0,437	0,188	-0,222	0,369	-0,077	96	-0,00080	0,000031	0,026	+S (11)
32	abcde	0,858	0,811	0,865	0,855	0,815	0,872	**5,076**	-0,141	-0,578	-0,766	-0,544	-0,913	96	-0,00951	0,004340	**3,683**	-S (10)
	Σ Y²	**17,742**	**18,159**	**18,669**	**18,564**	**18,155**	**18,632**											

Σ Y	**144,429**
Ukupna suma kvadrata odstupanja Σ Q = Σ Y² - (Σ Y)² =	**1,276020**
Korigirana, protumačena suma kvadrata odstupanja Σ Qt =	**1,087471**
Neprotumačeni ostatak - pogreška Qp = Σ Q - Σ Qt =	**0,188549**

Stupanj slobode glavnih efekata interakcije, s n = 5 faktora, Sst = 2^n - 1 =	**31**
Stupanj slobode ukupni, s r = 6 ponavljanja, Ssu = (2^n x r) - 1 =	**191**
Stupanj slobode ostatka - pogreške, Ssp = Ssu - Sst =	**160**
Varijanca ostatka $(\sigma_o)^2$ = Qp / Ssp =	**0,001178**
Kritična tab. vrijednost Ftab kod F -raspodjele za prag značajnosti α= 0,01	**2,200**

***Tablica 15**. Analiza varijance za kriterij **U** u pokusima **2^5** x 6 s većom proizvodnjom po narudžbi*

Pokusi U		Dobiveni rezultati (Y_{ijklm})Pi u ponavljanjima Pi						Σ YPi	Totali kombinacije tretmana					Div.	Efekti	Varianca	Frač. =	Značaj
									Y_i+Y_{i+1}	$(Y_i+Y_{i+1})'$	$(Y_i+Y_{i+1})''$	$(Y_i+Y_{i+1})'''$	$(Y_i+Y_{i+1})''''$					
R.br.	Stanje	P1	P2	P3	P4	P5	P6		$Y_{i+1}-Y_i$	$(Y_{i+1}-Y_i)'$	$(Y_{i+1}-Y_i)''$	$(Y_{i+1}-Y_i)'''$	$(Y_{i+1}-Y_i)''''$		E	$(\sigma_E)^2$	σ_E^2/σ_o^2	i rang
1		0,611	0,622	0,629	0,588	0,664	0,613	**3,727**	7,608	16,706	36,569	75,216	157,494	192	0,82028			
2	a	0,671	0,700	0,679	0,625	0,599	0,607	**3,881**	9,098	19,863	38,647	82,278	6,098	96	0,06352	0,193675	**150,903**	+VSSS (5)
3	b	0,698	0,685	0,674	0,739	0,773	0,693	**4,262**	8,913	17,725	40,564	3,056	13,892	96	0,14471	1,005144	**783,162**	+VSSS (1)
4	ab	0,809	0,844	0,735	0,776	0,792	0,880	**4,836**	10,950	20,922	41,714	3,042	-2,112	96	-0,02200	0,023232	**18,101**	-SS (7)
5	c	0,657	0,645	0,707	0,626	0,633	0,727	**3,995**	7,936	18,654	1,413	6,774	12,250	96	0,12760	0,781576	**608,967**	+VSSS (2)
6	ac	0,795	0,858	0,786	0,815	0,853	0,811	**4,918**	9,789	21,910	1,643	7,118	-1,170	96	-0,01219	0,007130	**5,555**	-S (8)
7	bc	0,909	0,967	0,938	0,930	0,937	0,913	**5,594**	9,764	19,537	1,686	-1,394	-0,348	96	-0,00363	0,000631	0,491	
8	abc	0,819	0,931	0,876	0,929	0,923	0,878	**5,356**	11,158	22,177	1,356	-0,718	-6,352	96	-0,06617	0,210145	**163,736**	-VSSS (4)
9	d	0,592	0,672	0,702	0,622	0,612	0,626	**3,826**	8,380	0,728	3,527	6,354	3,228	96	0,03363	0,054271	**42,285**	+SSS (6)
10	ad	0,653	0,672	0,743	0,686	0,711	0,645	**4,110**	10,274	0,685	3,247	5,896	-0,100	96	-0,00104	0,000052	0,041	
11	bd	0,764	0,776	0,750	0,803	0,679	0,768	**4,540**	10,118	0,993	3,568	-0,386	-0,298	96	-0,00310	0,000463	0,360	
12	abd	0,883	0,831	0,872	0,846	0,918	0,899	**5,249**	11,792	0,650	3,550	-0,784	0,758	96	0,00790	0,002993	**2,332**	+S (12)
13	cd	0,716	0,716	0,811	0,702	0,744	0,761	**4,450**	8,827	0,998	-0,741	0,088	-0,576	96	-0,00600	0,001728	1,346	
14	acd	0,809	0,932	0,925	0,857	0,898	0,893	**5,314**	10,710	0,688	-0,653	-0,436	-0,464	96	-0,00483	0,001121	0,874	
15	bcd	0,946	0,938	0,927	0,952	0,946	0,977	**5,686**	10,255	0,915	-0,694	-3,084	-1,002	96	-0,01044	0,005229	**4,074**	-S (10)
16	abcd	0,915	0,856	0,968	0,955	0,845	0,933	**5,472**	11,922	0,441	-0,024	-3,268	-0,066	96	-0,00069	0,000023	0,018	
17	e	0,649	0,692	0,655	0,708	0,665	0,680	**4,049**	0,154	1,490	3,157	2,078	7,062	96	0,07356	0,259749	**202,385**	+VSSS (3)
18	ae	0,699	0,724	0,725	0,726	0,778	0,679	**4,331**	0,574	2,037	3,197	1,150	-0,014	96	-0,00015	0,000001	0,001	
19	be	0,770	0,800	0,801	0,789	0,770	0,849	**4,779**	0,923	1,853	3,256	0,230	0,344	96	0,00358	0,000616	0,480	
20	abe	0,982	0,874	0,910	0,914	0,855	0,960	**5,495**	-0,238	1,394	2,640	-0,330	0,676	96	0,00704	0,002380	1,854	
21	ce	0,760	0,770	0,753	0,797	0,738	0,787	**4,605**	0,284	1,894	-0,043	-0,280	-0,458	96	-0,00477	0,001093	0,851	
22	ace	0,913	0,908	0,915	0,945	0,925	0,907	**5,513**	0,709	1,674	-0,343	-0,018	-0,398	96	-0,00415	0,000825	0,643	
23	bce	0,970	0,970	1,016	0,958	1,004	1,088	**6,006**	0,864	1,883	-0,310	0,088	-0,524	96	-0,00546	0,001430	1,114	
24	abce	0,951	0,931	1,027	0,994	0,967	0,916	**5,786**	-0,214	1,667	-0,474	0,670	-0,184	96	-0,00192	0,000176	0,137	
25	de	0,715	0,685	0,741	0,743	0,732	0,779	**4,395**	0,282	0,420	0,547	0,040	-0,928	96	-0,00967	0,004485	**3,495**	-S (11)
26	ade	0,727	0,723	0,724	0,745	0,792	0,721	**4,432**	0,716	-1,161	-0,459	-0,616	-0,560	96	-0,00583	0,001633	1,273	
27	bde	0,820	0,841	0,849	0,796	0,771	0,839	**4,916**	0,908	0,425	-0,220	-0,300	0,262	96	0,00273	0,000358	0,279	
28	abde	1,020	0,957	0,963	0,977	0,954	0,923	**5,794**	-0,220	-1,078	-0,216	-0,164	0,582	96	0,00606	0,001764	1,375	
29	cde	0,824	0,748	0,793	0,857	0,780	0,799	**4,801**	0,037	0,434	-1,581	-1,006	-0,656	96	-0,00683	0,002241	1,746	
30	acde	0,854	0,909	0,930	0,952	0,900	0,909	**5,454**	0,878	-1,128	-1,503	0,004	0,136	96	0,00142	0,000096	0,075	
31	bcde	0,957	1,005	1,048	1,023	1,011	1,023	**6,067**	0,653	0,841	-1,562	0,078	1,010	96	0,01052	0,005313	**4,140**	+S (9)
32	abcde	0,987	0,947	0,991	0,982	0,946	1,002	**5,855**	-0,212	-0,865	-1,706	-0,144	-0,222	96	-0,00231	0,000257	0,200	
	Σ Y²	**21,340**	**21,742**	**22,505**	**22,199**	**21,753**	**22,425**											

Σ Y	**157,494**
Ukupna suma kvadrata odstupanja Σ Q = Σ Y² - (Σ Y)² =	**2,775181**
Korigirana, protumačena suma kvadrata odstupanja Σ Qt =	**2,569830**
Neprotumačeni ostatak - pogreška Qp = Σ Q - Σ Qt =	**0,205351**

Stupanj slobode glavnih efekata interakcije, s n = 5 faktora, Sst = 2^n - 1 =	**31**
Stupanj slobode ukupni, s r = 6 ponavljanja, Ssu = (2^n x r) - 1 =	**191**
Stupanj slobode ostatka - pogreške, Ssp = Ssu - Sst =	**160**
Varijanca ostatka $(\sigma_o)^2$ = Qp / Ssp =	**0,001283**
Kritična tab. vrijednost Ftab kod F -raspodjele za prag značajnosti α= 0,01	**2,200**

Da li će u nekoj vrsti i tipu proizvodnje neki faktor biti drugačije utjecajan, odnosno da li će način planiranja i praćenja biti manje ili više utjecajan nije ključno za ovo istraživanje.

Treba također napomenuti da i sam izbor najznačajnijih utjecajnih faktora za istraživanje u nekom proizvodnom sustavu može biti promjenljiv od slučaja do slučaja jer će se proučavanjem postojećeg stanja u predmetnom proizvodnom sustavu utvrditi što je to što značajno utječe na uspješnost planiranja i praćenja proizvodnje.

Zato se dobar dio zaključaka zasnovan na pokazateljima iz obrađivanog primjera može sa zadovoljavajućom sigurnošću poopćiti i koristiti u daljnjem radu na istraživanju.

5.8. Zaključna analiza rezultata

Iz svih prethodnih analiza varijanci, za rezultate po pojedinačnim i sintetskom kriteriju, može se zaključiti sljedeće:

01. U pokusima po svim pokazateljima uspješnosti prema odabranim kriterijima pokazuje se puno veći značaj pojedinih faktora nego njihovih interakcija. Taj zaključak dobrim dijelom potvrđuju i pokusi 2^4 po sintetskom kriteriju U gdje su iz tretmana izostavljeni ili faktor B ili faktor C i gdje se tada vidi veća razlika utjecaja faktora i interakcija u odnosu na njihov utjecaj u pokusima 2^5. To potvrđuje pretpostavku da planiranje i praćenje kao proces-način rada značajno djeluje na uspješnost poslovnog sustava.
U ovom se istraživanju zapravo radilo s četiri modela-varijante oponašanja, odnosno četiri kombinacije faktora B i C na 1. i 2. nivou, što je potvrda gore navedenog zaključka.

02. Faktori C-način planiranja i praćenja i B-oblik plasmana proizvoda imaju izrazito najveći značaj djelovanja jer je zapravo svaki od njihovih nivoa tretiranja poseban, specifičan i različit model oponašanja pa je i veća razlika između njihovog 1. i 2. nivoa tretiranja.

03. Izraženije djelovanje interakcija AB i AC ukazuje na mogućnosti kako se kod četiri načina rada, praktično procesa operativnog planiranja i praćenja s obzirom na nivoe faktora A i faktora C, mora drugačije postavljati proces operativnog planiranja i praćenja proizvodnje s obzirom na oblik plasmana proizvoda.

To je moguće postići na način da se uz klizno planiranje i praćenje (faktor C na drugom nivou) pojača intenzitet prikupljanja ulaznih informacija (faktor A na drugom nivou) ili kada se uz prodaju većinom za poznatog kupca (faktor B na drugom nivou) prikuplja veći broj ulaznih informacija za proces (faktor A na drugom nivou).

04. Veći utjecaj interakcija pokazuje se kod pokusa po pokazatelju U_1-osjetljivost planiranja i praćenja i isti su negativnog utjecaja. Mogući uzrok takvih rezultata pokusa leži dijelom i u složenosti pokazatelja U_1 koji je zapravo skup više rezultata odnosa planova koji se zasnivaju na jednoj grupi informacija prema realizaciji proizvodnje i plasmana, a koje se zasnivaju na drugoj grupi parametara.

Pri tome se kod faktora B na drugom nivou čak pokazuje negativan utjecaj za što može biti više razloga, i to:

- još uvijek je kod faktora B na drugom nivou 40% nepoznatih kupaca pa su veće razlike planova i realizacije
- ostali poremećaji u podprocesima izazivaju veće razlike između planova i realizacije jer su ti potpocesi, odnosno ostali faktori još uvijek nestabilni na prvom nivou

05. Kod pokusa prema kriteriju U_2 uočava se mali utjecaj faktora A, dok su se faktori C, E i B pokazali kao najznačajniji.

Vjerojatni razlog tome je taj što se u pojednostavljenom modelu oponašanja nije obavilo određivanje prioriteta lansiranja serija-narudžbi u proizvodnju po kriteriju rokova.

Kod svih grupa pokusa po kriteriju U_2 nema izraženo značajnog utjecaja interakcija a pojavljuje se izuzetno pozitivan značaj faktora E što ukazuje na njegovu veliku ulogu u realizaciji poslova tretiranog procesa.

06. Faktori C i B su se očekivano pokazali kao najutjecajniji i prema kriteriju U_2 jer je i logično da se kod većeg učešća poznatih narudžbi kupaca, faktor B na drugom nivou, lakše unaprijed odrede i održe traženi rokovi isporuka.

Kod faktora C to proizlazi iz karaktera 2. nivoa tog faktora gdje se stalnim usklađivanjem planova i realizacije osigurava veća vjerojatnost zadovoljavanja traženih rokova.

07. U pokusima prema kriteriju U_3 također se pokazuje izrazito najveći utjecaj faktora B i C dok je utjecaj manjeg broja interakcija vrlo mali. Kada je faktor B na drugom nivou, što znači da imamo veći broj poznatih kupaca, lakše je odrediti i osigurati potrebne količine repromaterijala u traženom roku, a može se raditi sa manjim zalihama gotovih proizvoda.

Isto se događa i kada je faktor C na drugom nivou, tj. kada se češće usklađuju planovi i realizacija pa se na vrijeme mogu odrediti potrebne zalihe repromaterijala i proizvoda.

08. Pri analizi rezultata pokusa po sintetskom kriteriju U-uspješnost planiranja i praćenja vidi se izrazito velik i najveći utjecaj faktora C a zatim faktora B, nakon čega slijede osjetno manji, ali jako veliki utjecaji faktora A i E. Sve interakcije su malog značaja osim interakcije ABC koja i po sintetskom kriteriju U ima izraženo negativno djelovanje.

09. Kod pokusa 2^4 po sintetskom kriteriju U pokazuje se izraženo pozitivno djelovanje interakcija AB i AC za razliku od pokusa 2^5 po istom kriteriju, a što znači da na drugačiji način treba tretirati operativno planiranje i praćenje proizvodnje za slučaj kada imamo proizvodnju za poznatog kupca nego što se to radi kod proizvodnje za zalihe.

10. Prema dobivenim rezultatima oponašanja i faktorskog plana pokusa, datim u tablicama analize varijance, po pojedinim kriterijima ocjenjivanja dobivene su određene maksimalne vrijednosti, uz koje se ovdje zbog usporedbe navode i vrijednosti pokazatelja za sadašnji, snimljeni način rada, kako slijedi:

$(U_1)_{max} = 0{,}884$	$(U_1)_{sad.} = 0{,}794$
$(U_2)_{max} = 0{,}850$	$(U_2)_{sad.} = 0{,}787$
$(U_3)_{max} = 1{,}351$	$(U_3)_{sad.} = 0{,}957$
$U_{max} = 0{,}955$	$U_{sad.} = 0{,}601$

6. MODELIRANJE I OPTIMIZACIJA PLANIRANJA I PRAĆENJA

6.1. Poopćenje rezultata istraživanja na primjeru

Istraživanje na modelu temeljem raspoloživih podataka iz odabranog konkretnog primjera iz prakse u poglavlju 5. dovoljno je indikativno za donošenje nekih općih zaključaka u smislu pravaca daljnjeg razmatranja i tretiranja planiranja i praćenja proizvodnje. To više jer se radi o jednom klasičnom primjeru srednje velike, klasične metaloprerađivačke tvrtke, kojem je sličan velik broj proizvodnih sustava. Dobiveni rezultati istraživanja samo su smjernice i podloga za razmatranje načina i djelovanja tretiranih utjecajnih faktora na uspješnost planiranja i praćenja, a neki od njih se uz određena obrazloženja mogu i poopćiti.

Rezultati analize varijance za pretpostavljene slučajeve smanjene razlike između tretiranih nivoa faktora, u tablici 14. na stranici 108, i povećanog udjela proizvodnje za poznatog kupca, u tablici 15. na stranici 109, ukazuju da se dobar dio rezultata na korištenom primjeru iz prakse u ovom istraživanju može u određenoj mjeri poopćiti.

Da bi se moglo pouzdanije izvršiti poopćenja rezultata iz obrađenog primjera, prethodno će se izvršiti dodatna kraća analiza dobivenih rezultata u analizi varijance po svakom pojedinačnom i sintetskom kriteriju u pokusima 2^5, kao i za pokuse 2^4 po sintetskom kriteriju.

Prema pojedinačnim kriterijima faktor C-način planiranja i praćenja pokazao je najači utjecaj samo po pojedinačnom kriteriju U_2-zadovoljenost rokova, i to tek nešto više od faktora E-učestalost i vrijeme trajanja zastoja čovjeka, kako je to vidljivo u tablici 9. na stranici 97.

Bilo je i za očekivati da će faktor A-intenzitet prikupljanja ulaznih informacija imati velik, pa čak i najveći utjecaj po pojedinačnom kriteriju U_1-osjetljivost planiranja i praćenja, kako pokazuju rezultati u tablici 8. na stranici 94, a da će faktor B-oblik plasmana proizvoda imati najveći utjecaj po kriteriju U_3-efikasnost upravljanja zalihama, što se vidi u tablici 10. na stranici 100. ovog rada.

No, prema rezultatima po sintetskom kriteriju U-uspješnost planiranja i praćenja prikazanim u tablici 11. na stranici 102. faktor C, odnosno, način planiranja i praćenja se pokazuje kao izrazito najutjecajniji, što ujedno potvrđuje potrebu ocjenjivanja po više kriterija na sintetski način.

U istraživanju na konkretnom, praktičnom primjeru radilo se o kombiniranom načinu plasmana – za zalihe i za poznate kupce, po narudžbi.

No, to bi svakako trebalo razlučiti kao dvije različite grupe slučajeva proizvodnju i plasman sa zaliha u odnosu na proizvodnju i plasman po narudžbi što se u aktualnim znanstvenim radovima i istražuje odvojeno. Vrlo je vjerojatno da bi se u oba osnovna modela tipa proizvodnje s obzirom na plasman proizvoda način planiranja i praćenja također pokazao vrlo utjecajan.

Danas je sve važnije iznaći rješenja planiranja i praćenja u uvjetima velikih i nenadanih promjena u okruženju, a isto tako i u samom sustavu. Zato je u daljnjoj analizi potrebno sagledati djelovanje faktora A-intenzitet prikupljanja ulaznih informacija koji je zapravo skup većeg broja aktivnosti i informacija značajnih za uspješnost planiranja i praćenja. U istraživanju na konkretnom primjeru taj je faktor obuhvatio sljedeće aktivnosti i informacije:

a. pojavljivanje potencijalnih kupaca s narudžbama
b. vrste i količine traženih proizvoda s rokovima isporuke
c. mogući izvori snabdijevanja s repromaterijalima
d. potrebne vrste i količine repromaterijala s rokovima dobave
e. vrste i veličine raspoloživih kapaciteta
f. stanje svih vrsta zaliha
g. plan proizvodnje i isporuka
h. stanje realizacije u proizvodnji
i. poremećaji i zastoji u proizvodnji
j. raspoloživost ljudskih resursa
k. poremećaji i zastoji u radu čovjeka-izvršilaca

Iz rezultata analize varijance po sintetskom kriteriju U-uspješnost planiranja i praćenja faktora A-intenzitet prikupljanja ulaznih informacija pokazuje se po rangu tek kao 4. utjecajni faktor. To ukazuje da niti intenzivno prikupljanje ulaznih informacija nije dostatno za najjače djelovanje na uspješnost planiranja i praćenja. Što više, može se imati negativno djelovanje tog faktora u interakciji ABC s faktorima B i C, kako je to vidljivo u tablici 11. na stranici 102., a što je logično i pokazuje da se ne može imati uspješan proces planiranja i praćenja na način da se reagira na svaku promjenu u okruženju i poremećaj u sustavu.

No, pokusi 2^4 pokazuju da faktor A-intenzitet prikupljanja ulaznih informacija u slučaju proizvodenje za zalihe ima pozitivno djelovanje na uspješnost planiranja i praćenja u interakciji s faktorom C tj. načinom planiranja i praćenja (vidi tablicu 12. na stranici 105), kao i u slučaju kada se gotovi proizvodi proizvode i plasiraju većinom po narudžbi.

Kako je u pokusima 2^5 interakcija ABC negativna, to možemo pretpostaviti da prilikom rada po narudžbi, za poznatog kupca, ne treba intenzivno planiranje i praćenje proizvodnje. To ujedno znači da u tom slučaju informacije iz okruženja-tržišta trebaju periodički-kalendarski ulaziti u planove proizvodnje, odnosno obaviti ugovaranje s kupcima sukladno mogućnostima proizvođača jer bi u suprotnom vjerojatno imali negativno djelovanje interakcija AB i AC.

U tom slučaju bi bilo potrebno intenzivirati planiranje i praćenje, odnosno korekcije i usklađivanja planova proizvodnje, pri čemu ostaje pitanje kako i koliko intenzivno planirati i pratiti proizvodnju. Za očekivati je da bi intenzivno, klizno planiranje i praćenje proizvodnje dalo veće efekte u slučaju proizvodnje za zalihe ili kombinirane proizvodnje, a manji bi bili efekti takvog planiranja i praćenja u slučaju proizvodnje po narudžbama. Dio tih odgovora o odnosima između faktora A, B i C moguće je barem načelno dobiti u analizi pokusa 2^4.

U tablici 8. na stranici 94 vidi se da u slučaju proizvodnje za zalihe, kada je faktor B na 1. nivou, najveći utjecaj po kriteriju U_1-osjetljivost planiranja i praćenja ima faktor A- intenzitet prikupljanja ulaznih informacija, nešto malo više od faktora C-način planiranja i praćenja a njihova interakcija AC ima također veliki utjecaj.

Na efikasnost upravljanja zalihama, kriterij U_3, u slučaju proizvodnje za zalihe izrazito najveći utjecaj ima faktor C-način planiranja i praćenja, a značajan utjecaj pokazuju i faktori A-intenzitet prikupljanja ulaznih informacija i E-učestalost i vrijeme trajanja zastoja čovjeka, kako to pokazuju rezultati analize varijance u tablici 10. na stranici 100. U slučaju kada se ne tretira faktor C-način planiranja i praćenja, na efikasnost upravljanja zalihama najviše utječe faktor B-oblik plasmana proizvoda, odnosno proizvodnja po narudžbi što je i za očekivati, te faktor A- intenzitet prikupljanja ulaznih informacija.

Međutim, kada se gleda analiza varijance za rezultate po sintetskom kriteriju U u slučaju proizvodnje za zalihe, vidimo da način planiranja i praćenja, faktor C, ima daleko najveći utjecaj, osjetno više od faktora A- intenzitet prikupljanja ulaznih informacija i faktora E-učestalost i vrijeme trajanja zastoja čovjeka, kako to pokazuje tablica 11. na stranici 102.

Ako se pogledaju rezultati u tablici 13. na stranici 106 za slučaj analize varijance rezultata po sintetskom kriteriju U bez faktora C, vidi se da kod klasičnog kalendarskog planiranja najjači utjecaj ima faktor B-oblik plasmana proizvoda, a značajno djeluju faktori E-učestalost i vrijeme trajanja zastoja čovjeka i A- intenzitet prikupljanja ulaznih informacija.

Još jedna analiza djelovanja utjecajnih faktora može se napraviti za slučaj da interakciju AC tretiramo kao jedan kondenzirani faktor (AC) što ima logike jer se pretpostavlja da se kod kliznog planiranja i praćenja radi na bazi intenzivnog prikupljanja informacija o promjenama u okruženju i samom sustavu, što je i smisao modela kliznog planiranja i praćenja.

Analizirajući dobivene rezultate za tako postavljene pokuse 2^4 po svim pojedinačnim i sintetskim kriterijem u tablicama 16., 17., 18. i 19. vidi se da je utjecaj tog kondenziranog faktora izuzetno jači od bilo kojeg drugog faktora i značajnih interakcija po svim kriterijima.

Uz to se pokazuje veliki značaj faktora E - učestalost i vrijeme trajanja zastoja-čovjeka, odnosno poremećaja u radu ljudi.

To ukazuje na potrebu ozbiljnog tretiranja tog faktora i potrebe osposobljavanja ljudi u svim procesima pa se sa intenzivnim prikupljanjem i obradom ulaznih informacija uz klizno planiranje i praćenje proizvodnje mogu očekivati osjetno bolji rezultati bez obzira da li se radi po narudžbi ili za zalihe.

Sa zadovoljavajućom sigurnošću mogu se izvesti poopćeni zaključci o djelovanju navedenih utjecajnih faktora te načinu i pravcima njihovog tretiranja u daljnjem istraživanju, kako slijedi:

a. **Faktora A** – ovaj faktor je zapravo kondenzacija dva faktora, i to

   A_1 – intenzitet prikupljanja informacija iz okruženja (prodaja, nabava)

   A_2 – intenzitet prikupljanja informacija iz procesa proizvodnje

   - potrebno je odvojiti one aktivnosti i pripadajuće informacije koje su više vezane za izvršenja od strane zaposlenika te ih pridružiti faktoru E- učestalost i vrijeme trajanja, a uključiti one ulazne informacije koje pokazuju promjene u sustavu i njegovom okruženju bez utjecaja zaposlenika
   - obzirom da je u modelu kliznog planiranja i praćenja jedna od glavnih aktivnosti kontinuirano prikupljanje, sortiranje i obrada informacija koje su vezane za promjene u okruženju i samom sustavu, može se preporučiti kondenzacija tog dijela faktora s faktorom C, odnosno kliznim planiranjem i praćenjem, kao faktorom (AC)
   - prema prikazima u tablicama 16., 17., 18. i 19. vidljivo je da interakcija AC kao kondezirani faktor ima još veći utjecaj po svim kriterijima nego je to bilo kod prethodno izvedenih pokusa 2^5

Tablica 16**. Analiza varijance za kriterij U_1 u pokusima 2^4 x 6 s kondenziranim faktorima **A** i **C

Pokusi $U_{1(ac)}$ R.br.	Stanje	Dobiveni rezultati $(Y_{ijklm})_{Pi}$ u ponavljanjima Pi P1	P2	P3	P4	P5	P6	ΣY_{pi}	Totali kombinacije tretmana Y_i+Y_{i+1} / $Y_{i+1}-Y_i$	$(Y_i+Y_{i+1})'$ / $(Y_{i+1}-Y_i)'$	$(Y_i+Y_{i+1})''$ / $(Y_{i+1}-Y_i)''$	$(Y_i+Y_{i+1})'''$ / $(Y_{i+1}-Y_i)'''$	Diviz.	Efekti E	Varijanca $(\sigma_E)^2$	$F_{rač.} = \sigma_E^2/\sigma_o^2$	Značaj i rang
1		0,770	0,812	0,785	0,764	0,802	0,780	**4,713**	9,449	19,504	39,319	79,389	96	0,82697			
2	b	0,792	0,799	0,770	0,781	0,810	0,784	**4,736**	10,055	19,815	40,070	-1,203	48	-0,02506	0,015075	**66,000**	-SSS (3)
3	(ac)	0,866	0,876	0,890	0,859	0,865	0,854	**5,210**	9,616	19,961	-0,559	1,983	48	0,04131	0,040961	**179,332**	+VSSS (1)
4	b(ac)	0,786	0,815	0,808	0,810	0,826	0,800	**4,845**	10,199	20,109	-0,644	-1,569	48	-0,03269	0,025643	**112,269**	-VSSS (2)
5	d	0,771	0,803	0,816	0,788	0,787	0,778	**4,743**	9,779	-0,342	1,189	0,459	48	0,00956	0,002195	**9,608**	+S (5)
6	bd	0,802	0,834	0,806	0,823	0,797	0,811	**4,873**	10,182	-0,217	0,794	-0,109	48	-0,00227	0,000124	0,542	
7	(ac)d	0,862	0,895	0,882	0,867	0,895	0,872	**5,273**	9,859	-0,205	-0,865	-0,035	48	-0,00073	0,000013	0,056	
8	b(ac)d	0,812	0,800	0,847	0,840	0,809	0,818	**4,926**	10,250	-0,439	-0,704	0,077	48	0,00160	0,000062	0,270	
9	e	0,797	0,787	0,836	0,813	0,793	0,806	**4,832**	0,023	0,606	0,311	0,751	48	0,01565	0,005875	**25,721**	+SS (4)
10	be	0,810	0,845	0,813	0,829	0,818	0,832	**4,947**	-0,365	0,583	0,148	-0,085	48	-0,00177	0,000075	0,329	
11	(ac)e	0,855	0,880	0,862	0,890	0,886	0,878	**5,251**	0,130	0,403	0,125	-0,395	48	-0,00823	0,001625	**7,116**	-S (6)
12	b(ac)e	0,820	0,800	0,843	0,811	0,845	0,812	**4,931**	-0,347	0,391	-0,234	0,161	48	0,00335	0,000270	1,182	
13	de	0,827	0,805	0,824	0,845	0,841	0,830	**4,972**	0,115	-0,388	-0,023	-0,163	48	-0,00340	0,000277	1,212	
14	bde	0,810	0,834	0,807	0,823	0,798	0,815	**4,887**	-0,320	-0,477	-0,012	-0,359	48	-0,00748	0,001343	**5,878**	-S (7)
15	(ac)de	0,885	0,878	0,896	0,881	0,900	0,862	**5,302**	-0,085	-0,435	-0,089	0,011	48	0,00023	0,000001	0,006	
16	b(ac)de	0,822	0,828	0,844	0,805	0,834	0,815	**4,948**	-0,354	-0,269	0,166	0,255	48	0,00531	0,000677	2,965	
	ΣY^2	**10,722**	**11,059**	**11,124**	**10,957**	**11,087**	**10,817**										
							ΣY	**79,389**									

Ukupna suma kvadrata odstupanja $\Sigma Q = \Sigma Y^2 - (\Sigma Y)^2 =$	**0,112489**
Korigirana, protumačena suma kvadrata odstupanja $\Sigma Qt =$	**0,094216**
Neprotumačeni ostatak - pogreška $Qp = \Sigma Q - \Sigma Qt =$	**0,018273**

Stupanj slobode glavnih efekata interakcije, n = 4 faktora, $Sst = 2^n - 1 =$	**15**
Stupanj slobode ukupni, s r = 6 ponavljanja, $Ssu = (2^n \times r) - 1 =$	**95**
Stupanj slobode ostatka - pogreške, $Ssp = Ssu - Sst =$	**80**
Varijanca ostatka $(\sigma_o)^2 = Qp / Ssp =$	**0,000228**
Kritična tab. vrijednost Ftab kod F -raspodjele za prag značajnosti α= 0,01	**3,000**

Tablica 17**. Analiza varijance za kriterij U_2 u pokusima 2^4 x 6 s kondenziranim faktorima **A** i **C

Pokusi $U_{2(ac)}$ R.br.	Stanje	Dobiveni rezultati $(Y_{ijklm})_{Pi}$ u ponavljanjima Pi P1	P2	P3	P4	P5	P6	ΣY_{pi}	Totali kombinacije tretmana Y_i+Y_{i+1} / $Y_{i+1}-Y_i$	$(Y_i+Y_{i+1})'$ / $(Y_{i+1}-Y_i)'$	$(Y_i+Y_{i+1})''$ / $(Y_{i+1}-Y_i)''$	$(Y_i+Y_{i+1})'''$ / $(Y_{i+1}-Y_i)'''$	Diviz.	Efekti E	Varijanca $(\sigma_E)^2$	$F_{rač.} = \sigma_E^2/\sigma_o^2$	Značaj i rang
1		0,750	0,765	0,792	0,782	0,744	0,759	**4,592**	9,309	19,197	38,461	78,223	96	0,81482			
2	b	0,788	0,799	0,765	0,771	0,810	0,784	**4,717**	9,888	19,264	39,762	0,725	48	0,01510	0,005475	**23,282**	+SS (3)
3	(ac)	0,809	0,800	0,815	0,845	0,831	0,822	**4,922**	9,394	19,827	0,373	1,669	48	0,03477	0,029016	**123,383**	+VSSS (1)
4	b(ac)	0,818	0,846	0,830	0,828	0,836	0,808	**4,966**	9,870	19,935	0,352	-0,273	48	-0,00569	0,000776	**3,301**	-S (6)
5	d	0,760	0,796	0,783	0,767	0,757	0,751	**4,614**	9,687	0,169	1,055	0,175	48	0,00365	0,000319	1,356	
6	bd	0,791	0,818	0,787	0,796	0,780	0,808	**4,780**	10,140	0,204	0,614	-0,023	48	-0,00048	0,000006	0,023	
7	(ac)d	0,802	0,835	0,817	0,807	0,842	0,813	**4,916**	9,887	0,205	-0,209	-0,395	48	-0,00823	0,001625	**6,911**	-S (5)
8	b(ac)d	0,823	0,814	0,843	0,852	0,805	0,817	**4,954**	10,048	0,147	-0,064	0,059	48	0,00123	0,000036	0,154	
9	e	0,796	0,787	0,777	0,825	0,803	0,783	**4,771**	0,125	0,579	0,067	1,301	48	0,02710	0,017631	**74,971**	+SSS (2)
10	be	0,823	0,813	0,828	0,805	0,838	0,809	**4,916**	0,044	0,476	0,108	-0,021	48	-0,00044	0,000005	0,020	
11	(ac)e	0,843	0,850	0,855	0,827	0,845	0,820	**5,040**	0,166	0,453	0,035	-0,441	48	-0,00919	0,002026	**8,614**	-S (4)
12	b(ac)e	0,842	0,864	0,841	0,873	0,829	0,851	**5,100**	0,038	0,161	-0,058	0,145	48	0,00302	0,000219	0,931	
13	de	0,820	0,831	0,836	0,813	0,795	0,817	**4,912**	0,145	-0,081	-0,103	0,041	48	0,00085	0,000018	0,074	
14	bde	0,812	0,831	0,825	0,848	0,822	0,837	**4,975**	0,060	-0,128	-0,292	-0,093	48	-0,00194	0,000090	0,383	
15	(ac)de	0,813	0,849	0,825	0,840	0,823	0,832	**4,982**	0,063	-0,085	-0,047	-0,189	48	-0,00394	0,000372	1,582	
16	b(ac)de	0,835	0,855	0,825	0,863	0,847	0,841	**5,066**	0,084	0,021	0,106	0,153	48	0,00319	0,000244	1,037	
	ΣY^2	**10,451**	**10,824**	**10,645**	**10,810**	**10,588**	**10,496**										
							ΣY	**78,223**									

Ukupna suma kvadrata odstupanja $\Sigma Q = \Sigma Y^2 - (\Sigma Y)^2 =$	**0,076672**
Korigirana, protumačena suma kvadrata odstupanja $\Sigma Qt =$	**0,057858**
Neprotumačeni ostatak - pogreška $Qp = \Sigma Q - \Sigma Qt =$	**0,018814**

Stupanj slobode glavnih efekata interakcije, n = 4 faktora, $Sst = 2^n - 1 =$	**15**
Stupanj slobode ukupni, s r = 6 ponavljanja, $Ssu = (2^n \times r) - 1 =$	**95**
Stupanj slobode ostatka - pogreške, $Ssp = Ssu - Sst =$	**80**
Varijanca ostatka $(\sigma_o)^2 = Qp / Ssp =$	**0,000235**
Kritična tab. vrijednost Ftab kod F -raspodjele za prag značajnosti α= 0,01	**3,000**

Tablica 18**. Analiza varijance za kriterij **U_3** u pokusima **2^4** x 6 s kondenziranim faktorima **A** i **C

Pokusi **U3(ac)** R.br.	Stanje	Dobiveni rezultati (Y_{ijklm})Pi u ponavljanjima Pi P1	P2	P3	P4	P5	P6	**Σ Y_{pi}**	Totali kombinacije tretmana Y_i+Y_{i+1} / $Y_{i+1}-Y_i$	$(Y_i+Y_{i+1})'$ / $(Y_{i+1}-Y_i)'$	$(Y_i+Y_{i+1})''$ / $(Y_{i+1}-Y_i)''$	$(Y_i+Y_{i+1})'''$ / $(Y_{i+1}-Y_i)'''$	Diviz.	Efekti **E**	Varijanca $(\sigma_E)^2$	**$F_{rač.}$ = σ_E^2/σ_o^2**	Značaj i rang
1		1,058	1,002	1,011	0,984	1,112	1,035	**6,202**	12,770	27,328	55,429	112,782	96	1,17481			
2	b	1,068	1,023	1,094	1,177	1,128	1,078	**6,568**	14,558	28,101	57,353	3,722	48	0,07754	0,144305	**77,374**	+SSS (2)
3	(ac)	1,135	1,224	1,084	1,123	1,187	1,156	**6,909**	13,015	28,526	1,851	8,202	48	0,17088	0,700758	**375,736**	+VSSS (1)
4	b(ac)	1,214	1,290	1,246	1,325	1,276	1,298	**7,649**	15,086	28,827	1,871	0,378	48	0,00787	0,001488	0,798	
5	d	1,010	1,051	1,098	1,042	1,028	1,071	**6,300**	13,104	1,106	3,859	1,074	48	0,02238	0,012015	**6,442**	+S (4)
6	bd	1,154	1,087	1,133	1,176	1,043	1,122	**6,715**	15,422	0,745	4,343	-0,230	48	-0,00479	0,000551	0,295	
7	(ac)d	1,170	1,247	1,284	1,225	1,192	1,260	**7,378**	13,401	0,870	0,289	-0,010	48	-0,00021	0,000001	0,001	
8	b(ac)d	1,309	1,255	1,296	1,275	1,237	1,336	**7,708**	15,426	1,001	0,089	-0,310	48	-0,00646	0,001001	0,537	
9	e	1,023	1,117	1,008	1,056	1,045	1,078	**6,327**	0,366	1,788	0,773	1,924	48	0,04008	0,038560	**20,675**	+SS (3)
10	be	1,105	1,115	1,140	1,132	1,074	1,211	**6,777**	0,740	2,071	0,301	0,020	48	0,00042	0,000004	0,002	
11	(ac)e	1,267	1,214	1,241	1,284	1,235	1,260	**7,501**	0,415	2,318	-0,361	0,484	48	0,01008	0,002440	1,308	
12	b(ac)e	1,317	1,287	1,388	1,344	1,320	1,265	**7,921**	0,330	2,025	0,131	-0,200	48	-0,00417	0,000417	0,223	
13	de	1,055	1,024	1,075	1,082	1,095	1,149	**6,480**	0,450	0,374	0,283	-0,472	48	-0,00983	0,002321	1,244	
14	bde	1,187	1,154	1,215	1,080	1,115	1,170	**6,921**	0,420	-0,085	-0,293	0,492	48	0,01025	0,002522	1,352	
15	(ac)de	1,187	1,220	1,258	1,286	1,215	1,267	**7,433**	0,441	-0,030	-0,459	-0,576	48	-0,01200	0,003456	1,853	
16	b(ac)de	1,368	1,267	1,353	1,344	1,269	1,392	**7,993**	0,560	0,119	0,149	0,608	48	0,01267	0,003851	2,065	
	Σ Y^2	**21,866**	**21,724**	**22,591**	**22,614**	**21,684**	**23,081**										
							Σ Y	**112,782**									

Ukupna suma kvadrata odstupanja Σ Q = Σ Y^2 - $(Σ Y)^2$ =	**1,062893**
Korigirana, protumačena suma kvadrata odstupanja Σ Qt =	**0,913690**
Neprotumačeni ostatak - pogreška Qp = Σ Q - Σ Qt =	**0,149202**

Stupanj slobode glavnih efekata interakcije, n = 4 faktora, Sst = 2^n - 1 =	**15**
Stupanj slobode ukupni, s r = 6 ponavljanja, Ssu = (2^n x r) - 1 =	**95**
Stupanj slobode ostatka - pogreške, Ssp = Ssu - Sst =	**80**
Varijanca ostatka $(\sigma_o)^2$ = Qp / Ssp =	**0,001865**
Kritična tab. vrijednost Ftab kod F -raspodjele za prag značajnosti α= 0,01	**3,000**

Tablica 19**. Analiza varijance za kriterij **U** u pokusima **2⁴** x 6 s kondenziranim faktorima **A** i **C

Pokusi U(ac)		Dobiveni rezultati (Y_{ijklm})Pi u ponavljanjima Pi							Totali kombinacije tretmana					Efekti	Varijanca	**$F_{rač.}$ = σ_E^2/σ_o^2**	
R.br.	Stanje	P1	P2	P3	P4	P5	P6	**Σ Y_{pi}**	Y_i+Y_{i+1} $Y_{i+1}-Y_i$	$(Y_i+Y_{i+1})'$ $(Y_{i+1}-Y_i)'$	$(Y_i+Y_{i+1})''$ $(Y_{i+1}-Y_i)''$	$(Y_i+Y_{i+1})'''$ $(Y_{i+1}-Y_i)'''$	Div.	**E**	**$(\sigma_E)^2$**		Značaj i rang
1		0,611	0,622	0,629	0,588	0,664	0,613	**3,727**	7,803	17,836	36,550	76,306	96	0,79485			
2	b	0,667	0,653	0,644	0,709	0,740	0,663	**4,076**	10,033	18,714	39,756	1,914	48	0,03988	0,038160	**31,389**	+SS (3)
3	(ac)	0,795	0,858	0,786	0,815	0,853	0,811	**4,918**	8,172	19,672	0,980	8,970	48	0,18688	0,838134	**689,418**	+VSSS(1)
4	b(ac)	0,781	0,889	0,836	0,889	0,881	0,839	**5,115**	10,542	20,084	0,934	-1,434	48	-0,02988	0,021420	**17,620**	-SS (4)
5	d	0,592	0,672	0,702	0,622	0,612	0,626	**3,826**	8,625	0,546	4,600	1,290	48	0,02687	0,017334	**14,259**	+S (5)
6	bd	0,732	0,742	0,719	0,770	0,648	0,735	**4,346**	11,047	0,434	4,370	-0,274	48	-0,00571	0,000782	0,643	
7	(ac)d	0,809	0,932	0,925	0,857	0,898	0,893	**5,314**	9,068	0,548	-0,758	-0,334	48	-0,00696	0,001162	0,956	
8	b(ac)d	0,875	0,817	0,925	0,912	0,806	0,893	**5,228**	11,016	0,386	-0,676	-0,118	48	-0,00246	0,000145	0,119	
9	e	0,649	0,692	0,655	0,708	0,665	0,680	**4,049**	0,349	2,230	0,878	3,206	48	0,06679	0,107067	**88,069**	+SSS (2)
10	be	0,737	0,766	0,767	0,755	0,736	0,815	**4,576**	0,197	2,370	0,412	-0,046	48	-0,00096	0,000022	0,018	
11	(ac)e	0,913	0,908	0,915	0,945	0,925	0,907	**5,513**	0,520	2,422	-0,112	-0,230	48	-0,00479	0,000551	0,453	
12	b(ac)e	0,909	0,890	0,984	0,952	0,925	0,874	**5,534**	-0,086	1,948	-0,162	0,082	48	0,00171	0,000070	0,058	
13	de	0,715	0,685	0,741	0,743	0,732	0,779	**4,395**	0,527	-0,152	0,140	-0,466	48	-0,00971	0,002262	1,861	
14	bde	0,781	0,800	0,809	0,754	0,731	0,798	**4,673**	0,021	-0,606	-0,474	-0,050	48	-0,00104	0,000026	0,021	
15	(ac)de	0,854	0,909	0,930	0,952	0,900	0,909	**5,454**	0,278	-0,506	-0,454	-0,614	48	-0,01279	0,003927	**3,230**	-S (7)
16	bacde	0,939	0,897	0,942	0,934	0,896	0,954	**5,562**	0,108	-0,170	0,336	0,790	48	0,01646	0,006501	**5,348**	+S (6)
	Σ Y²	**9,723**	**10,300**	**10,627**	**10,619**	**10,121**	**10,397**										
							Σ Y	**76,306**									

Ukupna suma kvadrata odstupanja Σ Q = Σ Y² - (Σ Y)² =	**1,134822**
Korigirana, protumačena suma kvadrata odstupanja Σ Qt =	**1,037565**
Neprotumačeni ostatak - pogreška Qp = Σ Q - Σ Qt =	**0,097257**

Stupanj slobode glavnih efekata interakcije, n = 4 faktora, Sst = 2^n - 1 =	**15**
Stupanj slobode ukupni, s r = 6 ponavljanja, Ssu = (2^n x r) - 1 =	**95**
Stupanj slobode ostatka - pogreške, Ssp = Ssu - Sst =	**80**
Varijanca ostatka $(\sigma_o)^2$ = Qp / Ssp =	**0,001216**
Kritična tab. vrijednost Ftab kod F -raspodjele za prag značajnosti α= 0,01	**3,000**

b. **Faktor B** – uz primjenu kliznog planiranja i praćenja proizvodnje nije nužno odvojeno po posebnim modelima istraživati slučajeve različitih oblika plasmana proizvoda kako se već to zadnjih godina radi u brojnim istraživanjima

- eventualno zbog drugih spoznaja (upravljanje zalihama i sl.) može se odvojeno tretirati tri varijante oblika plasmana proizvoda, odnosno načina proizvodnje u odnosu na zalihe i narudžbe, i to:

1. proizvodnja za zalihe
2. proizvodnja po narudžbi
3. kombinirana proizvodnja

c. **Faktor C** – evidentno je da način planiranja i praćenja utječe na njegovu uspješnost pa ostaje samo pitanje kako i koliko, pri čemu je za očekivati da će više utjecati u slučaju proizvodnje za zalihe i kombinirane proizvodnje, a manje u slučaju pojedinačne proizvodnje po narudžbi

- model kliznog planiranja i praćenja može biti polazni model za svaku vrstu proizvodnje, a planska razdoblja i pomaci u klizanju tj. korekciji planova trebati će se određivati temeljem više parametara

c. **Faktor D** – za očekivati je da će učestalost i vrijeme trajanja zastoja strojeva biti manje utjecajno u odnosu na ostale faktore iz razloga što se razina kvalitete tehnologije proizvodnje i njeno održavanje osjetno podiglo zadnjih desetljeća a osim toga radi se o utjecajnom faktoru koji se može držati pod kontrolom

- u upravljanju proizvodnjom puno se vodi računa o stanju i raspoloživosti kapaciteta uz alternativna rješenja već kod izrade planova

e. **Faktor E** – učestalost i vrijeme trajanja zastoja-poremećaja u radu ljudi uključenih u tretirane procese proizvodnje, nabave, prodaje i planiranja pokazuje značajan utjecaj na uspješnost planiranja i praćenja

- taj će utjecaj biti to manji što je veća osposobljenost izvršilaca, ne samo u proizvodnji nego i u svim ostalim povezanim procesima, a također i u slučaju kada je stupanj organiziranosti poduzeća na višem nivou
- u prethodnom istraživanju na konkretnom primjeru čovjek je tretiran i kao subjekt i kao objekt obuhvaćenih procesa pa ako se u istraživanje uključe i drugi procesi u poduzeću, za očekivati je još veći utjecaj ovog faktora i zato ga se mora uvijek tretirati u svakom istraživanju

Vidljivo je da se kod svih tretiranih faktora zapravo radi o jednom ili više procesa proizvodnog poduzeća pri čemu se kod planiranja i praćenja proizvodnje radi i o izvršnom i o upravljačkom procesu, direktno i indirektno, što ukazuje da je planiranje i praćenje nešto više od izrade planova i izvještaja proizvodnje. Zbog toga se u istraživanjima uspješnosti planiranja i praćenja, a samim time i uspješnosti poslovanja proizvodnog poduzeća, trebaju tretirati procesi s onim njihovim aktivnostima po sadržaju i slijedu izvođenja koji utječu na uspješnost. Zato je pouzdanost tih procesa od značajnog utjecaja na uspješnost ukupnog poslovnog procesa-sustava, pri čemu se pod pouzdanosti podrazumijeva kvaliteta realizacije procesa-aktivnosti te rokovi izvršenja zadataka-obveza po svakom procesu i aktivnosti pa će način planiranja i praćenja biti ovisan i o pouzdanosti procesa u proizvodnom sustavu.

6.2. Ocjena kliznog planiranja i praćenja

Ocjena primjene kliznog planiranja i praćenja može se dobiti testiranjem značajnosti razlike dobivenih rezultata uspješnosti kod primjene takvog načina rada za dva slučaja:

1. kombinirana proizvodnja, za zalihe i većim dijelom po narudžbi, za poznate kupce
2. proizvodnja za zalihe, a manjim dijelom po narudžbi, za poznate kupce

U prvom slučaju testirati će se značajnost razlike dobivenih rezultata istraživanjem na modelu, tj. oponašanjem i faktorskim planom pokusa. Tu će se usporediti dobiveni rezultati po odabranim kriterijima za slučaj kada su svi faktori na 1. nivou u odnosu na pokus gdje su faktori A-intenzitet prikupljanja ulaznih informacija i C-način planiranja i praćenja bili na 2. nivou, a to je u faktorskom planu pokusa interakcija AC. Naime, kako je 2. nivo faktora C primjena kliznog planiranja i praćenja koje implicira kontinuirano prikupljanje, sistematizaciju i obradu informacija o promjenama u okruženju i samom sustavu, trebaju se testirati rezultati interakcije AC u odnosu na polazno stanje, tj. kada su svi faktori na 1. nivou.

U drugom slučaju izvršiti će se usporedba dobivenih rezultata iz istraživanja na modelu za slučaj kada se primjenjivalo klizno planiranje i praćenje u slučaju proizvodnje većim dijelom za poznate kupce. To je slučaj kada su faktori A-intenzitet prikupljanja ulaznih informacija, B-oblik plasmana proizvoda i C-način planiranja i praćenja bili na 2. nivou, a to je u faktorskom planu pokusa interakcija ABC. I ovdje se impliciralo da je faktor A uvijek na 2. nivou kada se primjenjuje klizno planiranje i praćenje, tj. imamo faktor C na 2. nivou.

Za testiranje će se koristiti **t**–test koji se obično primjenjuje kada se uspoređuju mali uzorci kao što je to ovdje slučaj, pošto je kod svakog pokusa bilo po 6 uzoraka jer se radilo sa 6 ponavljanja pokusa. Tablica **t**-distribucije je slična tablici normalne distribucije, a razlika je u tome što je kod **t**-distribucije tablica dvodimenzionalna za svaki stupanj slobode **r** i dato **t**.

Testirati će se postavka da postoji značajna razlika uspješnosti kliznog planiranja i praćenja u odnosu na polazno stanje i način rada za oba navedena slučaja proizvodnje, a rezultati će se testirati uz 95%-tnu vjerojatnost, što znači da je α=0,05. Postavka će se prihvatiti za slučaj da apsolutna izračunata vrijednost $\mathbf{t}_{\boldsymbol{rač.}}$ bude veća od tabelarne vrijednosti $\mathbf{t}_{\mathbf{1-\alpha/2}}$= 2,634 koja je dobivena za α/2 = 0,025 i broj stupnjeva slobode **r** = 10, gdje je r = n_1+ n_2 – 2 pri čemu je n_1=6 i n_2=6 tj. veličine uzoraka, odnosno ponavljanja u uspoređivanim pokusima-uzorcima.

Rezultati testiranja u modelu za većinsku proizvodnju za zalihe prikazan je u tablici 20., a za drugi slučaj, kombiniranu proizvodnju s većinskom proizvodnjom po narudžbi, odnosno poznatog kupca, rezultati su prikazani u tablici 21.

Tablica 20. *Usporedba i testiranje pokazatelja uspješnosti i prilagodljivosti primjenom kliznog planiranja i praćenja u modelu za proizvodnju većinom za zalihe*

Kriterij i mjesto ocjenjivanja		Dobiveni rezultati x_i	$(s_o)^2$	s_d	t
1. Osjetljivost planiranja $\mathbf{U_1}$	1.1. faktori na 1. nivou, 6 ponavljanja	0,784	0,00040	0,013	$t_{rač.}$=6,385
	1.2. interakcija AC, 6 ponavljanja	0,868	0,00015	0,013	$t_{\alpha=0,025}$=2,634
2. Zadovoljenost rokova $\mathbf{U_2}$	2.1. faktori na 1. nivou, 6 ponavljanja	0,765	0,00040	0,018	$t_{rač.}$ =3,111
	2.2. interakcija AC, 6 ponavljanja	0,820	0,00026	0,018	$t_{\alpha=0,025}$=2,634
3. Efikasnost zaliha $\mathbf{U_3}$	3.1. faktori na 1. nivou, 6 ponavljanja	1,034	0,00160	0,045	$t_{rač.}$ =2,622
	3.2. interakcija AC, 6 ponavljanja	1,152	0,00240	0,045	$t_{\alpha=0,025}$=2,634
4. Uspješnost planiranja **U**	4.1. faktori na 1. nivou, 6 ponavljanja	0,601	0,00070	0,028	$t_{rač.}$ =7,143
	4.2. interakcija AC, 6 ponavljanja	0,820	0,00084	0,028	$t_{\alpha=0,025}$=2,634

Tablica 21. *Usporedba i testiranje pokazatelja uspješnosti i prilagodljivosti primjenom kliznog planiranja i praćenja u modelu za proizvodnju većinom po narudžbi*

Kriterij i mjesto ocjenjivanja		Dobiveni rezultati x_i	$(s_o)^2$	s_d	t
1. Osjetljivost planiranja $\mathbf{U_1}$	1.1. faktori na 1. nivou, 6 ponavljanja	0,784	0,00040	0,017	$t_{rač.}$ =1,353
	1.2. interakcija ABC, 6 ponavljanja	0,808	0,00029	0,017	$t_{\alpha=0,025}$=2,634
2. Zadovoljenost rokova $\mathbf{U_2}$	2.1. faktori na 1. nivou, 6 ponavljanja	0,765	0,00040	0,017	$t_{rač.}$ =3,706
	2.2. interakcija ABC, 6 ponavljanja	0,828	0,00029	0,017	$t_{\alpha=0,025}$=2,634
3. Efikasnost zaliha $\mathbf{U_3}$	3.1. faktori na 1. nivou, 6 ponavljanja	1,034	0,00160	0,035	$t_{rač.}$ =4,820
	3.2. interakcija ABC, 6 ponavljanja	1,275	0,00333	0,050	$t_{\alpha=0,025}$=2,634
4. Uspješnost planiranja **U**	4.1. faktori na 1. nivou, 6 ponavljanja	0,621	0,00070	0,024	$t_{rač.}$ =5,659
	4.2. interakcija ABC, 6 ponavljanja	0,853	0,00263	0,041	$t_{\alpha=0,025}$=2,634

Na slici 15. dat je grafički prikaz rezultata usporedbe i testiranja pokazatelja uspješnosti i prilagodljivosti kliznog planiranja i praćenja za modele:

1. O – svi faktori na 1. nivou, proizvodnja većinom za zalihe
2. AC – faktori A i C na 2. nivou, proizvodnja većinom za zalihe
3. ABC - faktori A, B i C na 2. nivou, proizvodnja većinom za narudžbe

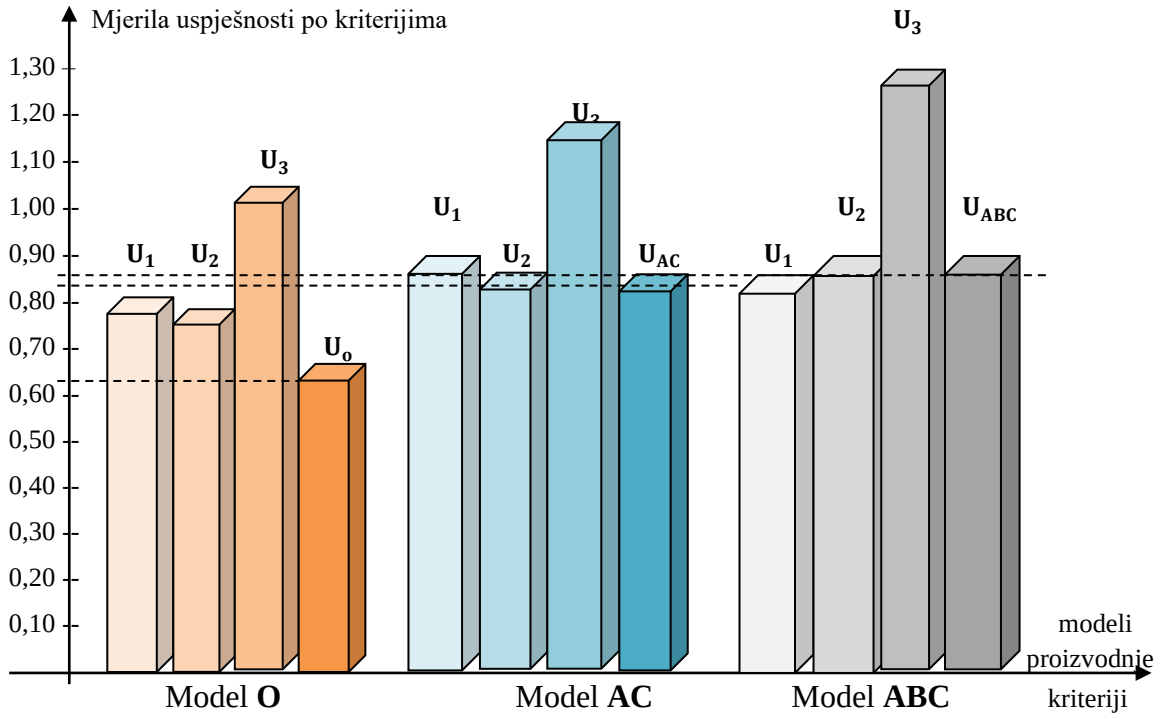

Slika 15. *Prosječna odstupanja rezultata modela optimizacije od stvarne realizacije*

U slučaju usporedbe i testiranja pokazatelja uspješnosti i prilagodljivosti primjenom kliznog planiranja i praćenja u modelu za proizvodnju većinom za zalihe, tablica 19., vidi se da nema značajne razlike rezultata samo po kriteriju U_3- efikasnost upravljanja zalihama, što je i bilo za očekivati, dok se po ostalim i sintetskom kriteriju pokazuje značajna razlika. Stoga se može reći da se u primjeru iz istraživanja klizno planiranje i praćenje proizvodnje pokazalo značajno utjecajnim na uspješnost planiranja i praćenja proizvodnje, a što ujedno potvrđuje klizno planiranje i praćenje kao model prilagodljivog planiranja i praćenja proizvodnje.

U slučaju usporedbe i testiranja pokazatelja uspješnosti i prilagodljivosti primjenom kliznog planiranja i praćenja u modelu za proizvodnju većinom po narudžbi, tablica 20., nema značajne razlike uspoređivanih faktorskih pokusa samo po kriteriju U_1- osjetljivost planiranja i praćenja. I to je bilo za očekivati jer kod čestih i značajnih promjena planova proizvodnje, zbog usklađivanja prema potrebama-narudžbama kupca, biti će manja osjetljivost planiranja.

Po svim ostalim kriterijima i sintetskom kriteriju za primjer iz istraživanja klizno planiranje i praćenje proizvodnje pokazalo se značajno utjecajnim na uspješnost planiranja i praćenja proizvodnje. To ujedno potvrđuje da se klizno planiranje i praćenje može uspješno primijeniti kao prilagodljivi model planiranja i praćenja i u slučaju kada se radi o proizvodnji po narudžbi.

Naravno, stupanj uspješnosti i prilagodljivosti kod primjene kliznog planiranja i praćenja proizvodnje neće i ne može biti kontinuirano jednak u nekom proizvodnom sustavu i razlikovati će se od sustava do sustava jer je ovisno o ograničenjima sustava te vrstama, obujmu i intenzitetu promjena u okolini i samom sustavu.

Kliznim planiranjem i praćenjem rješava se trenutno moguće i usklađuje buduće pa stoga može biti opći model i ishodište za modeliranje procesa planiranja i praćenja za pojedinačne slučajeve. Njime se također mogu povezati matematičke metode optimizacije i praktična zbivanja u obliku promjena u sustavu i okruženju u toku realizacije, na način da se iste pravovremeno tretiraju i osigura minimalno odstupanje planiranih rezultata, ako ne i njihovo povećanje. Na taj način klizno planiranje i praćenje spaja teoretske postavke i praktične uvjete optimizacije proizvodnje-poslovanja pa se može smatrati modelom prilagodljivog planiranja i praćenja proizvodnje.

6.3. Regresijska analiza rezultata pokusa

Zbog cjelovitije i preciznije obrade rezultata ovog istraživanja i dobivanja podloga za utvrđivanje postupka određivanja procesa planiranja i praćenja proizvodnje napravljena je regresijska analiza rezultata pokusa. Za to je odabran faktorski plan pokusa $\boldsymbol{2^4}$ *x 6* s kondenziranim faktorima A i C kao faktorom (AC) te faktorima B, D i E za koje se zasigurno može očekivati da će biti u svakom proizvodnom sustavu relevantni za određivanje procesa planiranja i praćenja proizvodnje. Dobiveni rezultati tog faktorskog pokusa po sintetskom kriteriju U prikazani u tablici 19. na stranici 120.

Regresijska analiza će se primijeniti zbog provjere značajnosti rezultata složenih pokusa sa više faktora i više rezultata gdje je zamjenjivanje bilo kakve funkcije linearnim polinomom aproksimacija s pogreškom. Aproksimacija će biti bolja koliko će greška biti manja, a minimalna pogreška nastaje kad su najtočnije određeni koeficijenti regresije. Rezultati regresijske analize za faktorski plan pokusa $\boldsymbol{2^4}$ *x 6* s kondenziranim faktorima A i C prikazani su u tablici 22.

Najprije će se napraviti provjera jednorodnosti rasipanja svih dobivenih rezultata za što je prema izrazu (29) izračunato rasipanje s_y^2 rezultata svakog pokusa

$$s_{yi}^2 = \frac{1}{n-1}\Sigma(y_{ij} - \bar{y}_i) \tag{29}$$

gdje je: y_{ij} - rezultati iz svakog pokusa po kriteriju U

$\bar{y}_i$ - srednja vrijednost rezultat iz svakog pokusa po kriteriju U

U tom slučaju se provjerava jednorodnost pojedinačnih rasipanja pomoću Kohrenovog kriterija $\boldsymbol{G_{max}}$ odnosa najveće od svih rasipanja s_{yi}^2 prema sumi svih rasipanja po izrazu (30)

$$\boldsymbol{G_{max}} = \max s_{yi}^2 / \Sigma s_{yi}^2 \tag{30}$$

sa stupnjevima slobode (k-1) i n(k-1) za odabranu vjerojatnost 1-α pa ako je $G_{max} < G_{tab.}$ onda su rasipanja jednorodna uz vjerojatnost 1-α.

U ovom slučaju je G_{max}= 0,138 a $G_{tab.}$=0,210 i pošto je utvrđeno da je $G_{max} < G_{tab.}$, potvrđuje se da su rasipanja jednorodna pa se nadalje može računati sa srednjim rasipanjem s^2 koje se izračunava prema izrazu (31)

$$s^2 = 1/N \cdot \Sigma s_i^2 \tag{31}$$

a za 16 pokusa sa 6 ponavljanja je broj stupnjeva slobode N=16(6-1)=80 pa je s^2=0,00022.

Sada se može izvršiti regresijska analiza rezultata prikazanih u tablici 22.

Tablica 22. *Regresijska analiza rezultata pokusa* ***2⁴*** *x 6 s kondenziranim faktorima* ***A*** *i* ***C***

		Ponavljanja pokusa																							
		P1	**P2**	**P3**	**P4**	**P5**	**P6**	x_o	x_1	x_2	x_3	x_4	x_1x_2	x_1x_3	x_1x_4	x_2x_3	x_2x_4	x_3x_4	$x_1x_2x_3$	$x_1x_2x_4$	$x_2x_3x_4$	$x_1x_3x_4$	$x_1x_2x_3x_4$	$\bar{y}$	s_y^2	$\hat{y}$
1	(1)	0,611	0,622	0,629	0,588	0,664	0,613	+	-	-	-	-	+	+	+	+	+	+	-	-	-	-	+	0,621	0,00063	0,626
2	b	0,667	0,653	0,644	0,709	0,740	0,663	+	+	-	-	-	-	-	-	+	+	+	+	+	-	+	-	0,679	0,00139	0,680
3	(ac)	0,795	0,858	0,786	0,815	0,853	0,811	+	-	+	-	-	-	+	+	-	-	+	+	+	+	-	-	0,820	0,00089	0,822
4	b(ac)	0,781	0,889	0,836	0,889	0,881	0,839	+	+	+	-	-	+	-	-	-	-	+	-	-	+	+	+	0,853	0,00181	0,848
5	d	0,592	0,672	0,702	0,622	0,612	0,626	+	-	-	+	-	+	-	+	-	+	-	+	-	+	+	+	0,638	0,00169	0,642
6	bd	0,732	0,742	0,719	0,770	0,648	0,735	+	+	-	+	-	-	+	-	-	+	-	-	+	+	-	+	0,724	0,00169	0,728
7	(ac)d	0,809	0,932	0,925	0,857	0,898	0,893	+	-	+	+	-	-	-	+	+	-	-	-	+	-	+	+	0,886	0,00212	0,878
8	b(ac)d	0,875	0,817	0,925	0,912	0,806	0,893	+	+	+	+	-	+	+	-	+	-	-	+	-	-	-	-	0,871	0,00245	0,875
9	e	0,649	0,692	0,655	0,708	0,665	0,680	+	-	-	-	+	+	+	-	+	-	-	-	+	+	+	-	0,675	0,00056	0,674
10	be	0,737	0,766	0,767	0,755	0,736	0,815	+	+	-	-	+	-	-	+	+	-	-	+	-	+	-	+	0,763	0,00083	0,760
11	(ac)e	0,913	0,908	0,915	0,945	0,925	0,907	+	-	+	-	+	-	+	-	-	+	-	+	-	-	+	+	0,919	0,00021	0,931
12	b(ac)e	0,909	0,890	0,984	0,952	0,925	0,874	+	+	+	-	+	+	-	+	-	+	-	-	+	-	-	-	0,922	0,00165	0,920
13	de	0,715	0,685	0,741	0,743	0,732	0,779	+	-	-	+	+	+	-	-	-	-	+	+	+	-	-	+	0,733	0,00098	0,726
14	bde	0,781	0,800	0,809	0,754	0,731	0,798	+	+	-	+	+	-	+	+	-	-	+	-	-	-	+	-	0,779	0,00093	0,780
15	(ac)de	0,854	0,909	0,930	0,952	0,900	0,909	+	-	+	+	+	-	-	-	+	+	+	-	-	+	-	-	0,909	0,00108	0,906
16	b(ac)de	0,939	0,897	0,942	0,934	0,896	0,954	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	0,927	0,00060	0,932

U tu svrhu se prvo određuju koeficijenti regresije prema izrazu (32)

$$b_i = 1/n \cdot \Sigma x_{ij}\bar{y}_i \tag{32}$$

te se utvrđuju koeficijenti regresije kako slijedi:

b_0= 0,795 b_1=+0,020 b_2=+0,093 b_{12}= -0,015 b_3=+0,013 b_{13}= -0,002
b_{23}= -0,004 b_{123}= -0,001 b_4=+0,033 b_{14}= -0,000 b_{24}= -0,002 b_{124}=+0,001
b_{34}= -0,005 b_{134}= -0,000 b_{234}= -0,006 b_{1234}=+0,008

Rasipanje pogreške ocjenjivanja koeficijenata regresije izračunava se prema izrazu (33)

$$s_{bi}^2 = s^2/n \cdot k \tag{33}$$

pa je s_{bi}^2=0,0000023, što daje standardno odstupanje od s_{bi}=0,0015.

Studentov kriterij pri 16 stupnjeva slobode i vjerojatnost od 95% iznosi 1,75 a kritični koeficijent regresije izračunat prema izrazu (34)

$$b_{krit.} = t \cdot s_{bi} \tag{34}$$

iznosi $b_{krit.}$=0,0027 pa su neznačajni koeficijenti regresije oni koji su manji od tog iznosa i neće se uvrstiti u regresijsku funkciju koja sada glasi

$$\hat{\boldsymbol{y}} = 0{,}795 + 0{,}020x_1 + 0{,}093x_2 - 0{,}015x_1x_2 + 0{,}013x_3 - 0{,}004x_2x_3 + 0{,}033x_4 - 0{,}005x_3x_4 - 0{,}006x_2x_3x_4 + 0{,}008x_1x_2x_3x_4$$

Regresijska funkcija pokazuje analogne utjecaje faktora i interakcija kao kod analize varijance što potvrđuje ispravnost oba postupka i samog faktorskog plana pokusa.

Provjera neadekvatnosti aproksimacije regresijskim polinomom izvršena je preko rasipanja $s_{nead.}^2$ izračunate prema izrazu (35)

$$s_{nead.}^2 = 1/(n-d) \cdot \Sigma(y_{ij} - \bar{y}_i)^2 \tag{35}$$

gdje je **d** broj članova regresijskog polinoma, i iznosi $s_{nead.}^2$=0,000064.

Fisherov kriterij $\boldsymbol{F_{tab.}}$=2,74 za 6 i 16 stupnjeva slobode uz α=0,05, a kako je odnos neadekvatnosti $\boldsymbol{v}_o$= 0,29, izračunat prema izrazu (36)

$$\boldsymbol{v}_o = s_{nead.}^2/s^2 \tag{36}$$

manji od $\boldsymbol{F_{tab.}}$=2,74, potvrđuje se sa vjerojatnosti od 95% da je model adekvatan.

Dobiveni rezultati potvrđuju da se faktorski plan pokusa s odgovarajućim modelom oponašanja može koristiti u postupku određivanja procesa planiranja i praćenja proizvodnje.

6.4. Modeliranje prilagodljivog planiranja i praćenja

Modeliranje planiranja i praćenja treba biti okvir za njegovu optimizaciju u buduću razradu u praksi po svim potrebnim elementima i treba stvoriti uvjete za njegovu realnu i stvarno moguću optimizaciju planova proizvodnje putem povezivanja stvarnog stanja u sustavu i okruženju s uvjetima i ograničenjima koje postavljaju metode i tehnike optimizacije.

Za to se ovdje modeliranjem nastoji u mogućoj, realnoj mjeri odrediti tipične i najčešće modele strukture i procesa proizvodnog sustava kako bi se optimiranje rješenja izvršilo lakše, vjerodostojnije i efikasnije. To znači da se modeliranjem želi smanjiti razlika između uvjeta i ograničenja matematičkih metoda i tehnika optimizacije i zbivanja i pokazatelja u tretiranom sustavu, prema odabranim ciljevima, kriterijima i mjerilima.

Poznato je da danas raspoložive metode i tehnike optimizacije postavljaju uvjete i ograničenja koja gotovo uvijek u većoj ili manjoj mjeri odstupaju od stvatnog stanja problema koji se želi rješavati. Zato se smatra da se postavljanjem odgovarajućih modela tretiranja sustava i njegovih procesa na osnovu logičkih i iskustvenih spoznaja, uključujući specifičnosti svakog pojedinog sustava, omogućava veći stupanj realizacije izabranih optimalnih rješenja prilikom njihovog sprovođenja u život.

Drugi razlog za modeliranje sustava i procesa prije same optimizacije budućih rješenja planova proizvodnje je omogućavanje boljeg izbora i izvođenja optimizacije rješenja. To se treba raditi ne samo na bazi podloga i zakonitosti iz prethodnih razdoblja već i korištenjem informacija iz trenutne, aktualne situacije u sustavu i njegovom okruženju, uz manju ili veću povezanost s prethodno utvrđenim zakonitostima i parametrima.

Zato se pod modeliranjem procesa planiranja i praćenja ovdje podrazumijeva definiranje i oblikovanje načina izvođenja tog procesa u smislu njegovog obuhvata i dinamike promatrano u vremenu. To uključuje i veze sa procesima s kojima je planiranje i praćenje intenzivno povezano i uvjetovano te uvjete u promatranom sustavu i njegovom okruženju. Cilj je da ne samo proces planiranja i praćenja već i cijeli proizvodni sustav-poduzeće bude prilagodljiv i uspješan. Stoga je neophodno razmotriti ciljeve i parametre modeliranja, a zatim utvrditi modele procesa planiranja i praćenja.

Pred planiranje i praćenje se postavlja više zahtjeva koji su dobrim dijelom jedni drugima suprostavljeni, a to je:

a. osigurati kontinuitet i stabilnost proizvodnje
b. maksimalno zadovoljiti potrebe okoline
c. optimizirati ciljeve i interese sustava
d. uklanjati poremećaje i svesti ih na minimalnu mjeru
e. povezivati proizvodnju s ostalim procesima uz sudjelovanje u upravljanju sustavom

Pri tome se u procesu planiranja i praćenja proizvodnje obavlja veći broja grupa različitih aktivnosti kao što su prijem i obrada informacija, izrada planova i izvještaja, donošenje odluka, suradnja i koordinacija s drugima, osiguranje uvjeta za realizaciju planova i dr.

Složenost odvijanja procesa planiranja i praćenja vidljiva je iz kratkog shematskog prikaza na slici 16.

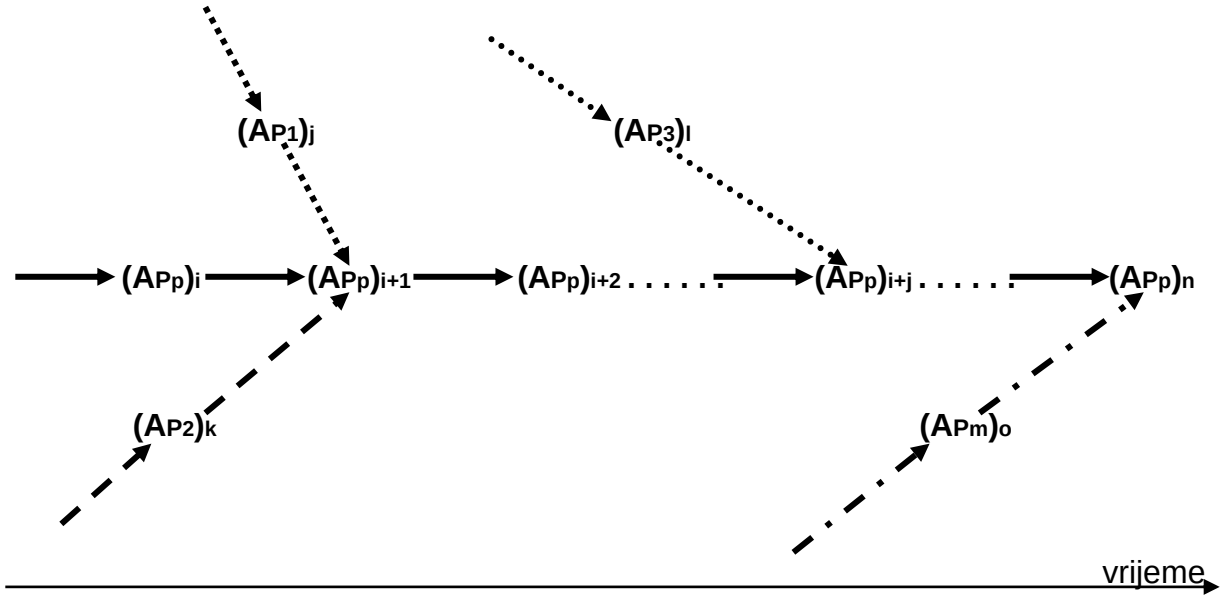

Legenda: **(APp)i** - aktivnost u procesu planiranja i praćenja
(APm)o- aktivnost u drugim procesima sustava

Slika 16. *Shema odvijanja procesa planiranja i praćenja*

Svaka od aktivnosti u svakom procesu sustava nosi i određene informacije, uključujući i informacije o promjenama i poremećajima u sustavu i njegovom okruženju. Stoga će svaki proces biti onoliko pouzdan koliko se u cijelosti, kvalitetno i na vrijeme obavlja svaka njegova aktivnost, odnosno, koliko se na vrijeme uočavaju poremećaji i evidentiraju promjene te se na njih odgovarajuće djeluje.

Naravno, ne postoji takav proces-sustav koji može reagirati na sve promjene i poremećaje jer je svaki strukturiran i organiziran na način da radi u manje-više stabilnim uvjetima pa se može samo govoriti o optimalnom djelovanju u datim okolnostima.

Modeliranjem procesa planiranja i praćenja trebalo bi definirati koja su to planska razdoblja za neki proizvodni-poslovni sustav i koliko često i kada korigirati i usklađivati planove da bi se optimiranjem planiranja i praćenja moglo postići maksimalno moguće ostvarenje interesa sustava realizacijom postavljenih planova uz optimalnu prilagodljivost i zadovoljenje potreba okoline.

Klizno planiranje i praćenje može biti opći model i polazište za modeliranje procesa planiranja i praćenja za pojedinačne slučajeve jer se njime mogu povezati matematičke metode optimizacije i praktična zbivanja u obliku promjena u sustavu i okruženju tijekom realizacije. To treba izvesti tako da se iste pravovremeno tretiraju i osigura minimalno odstupanje planiranih rezultata, ako ne i njihovo povećanje. Na taj način klizno planiranje i praćenje spaja teoretske postavke i praktične uvjete optimizacije proizvodnje-poslovanja.

Kako nije moguće odrediti jedinstveni model-rješenje načina izvođenja procesa planiranja i praćenja, potrebno je razmotriti osnovne modele proizvodnje-poslovanja. Naime, evidentno je da brojne specifičnosti vrsta i načina proizvodnje i poslovanja uz različite uvjete u njihovom okruženju utječu na izbor rješenja načina planiranja i praćenja pa ne postoji jedinsveni model, odnosno rješenje tog procesa.

Broj isporuka je treći parametar koji tipizira neku proizvodnju i vezan je za broj kupaca, odnosno narudžbi, ali je relevantniji za daljnje istraživanje jer bolje oslikava proizvodnju i poslovanje. To treba učiniti i u slučaju manjeg broj kupaca i narudžbi kada se može imati veći broj isporuka, a što je važnije za planiranje i praćenje bez obzira da li se radi o proizvodnji za zalihe ili po narudžbi.

U svrhu modeliranja planiranja i praćenja, prvi korak bi trebalo biti određivanje OSNOVNOG PLANSKOG RAZDOBLJA koji predstavlja razdoblje za koje se radi primarni, polazni operativni plan. Kako je teško egzaktno odrediti osnovno plansko razdoblje, ovdje se predlažu njegove tri osnovne varijante određene prema prethodno navedenim parametrima. Dodatni faktori o kojima se još vodilo računa kod određivanja varijanti osnovnog planskog razdoblja su razlozi financijsko-računovodstvenih i zakonskih okvira pa se temeljem navedenog predlažu sljedeće varijante osnovnog planskog razdoblja, i to:

1. **Duže osnovno plansko razdoblje, u trajanju od 6 mjeseci**
   - za slučaj proizvodnje po narudžbi, veće kompleksnost i manjeg broja isporuka
2. **Srednje osnovno plansko razdoblje, u trajanju od 3 mjeseca**
   - za slučaj proizvodnje po narudžbi, veće kompleksnosti i većeg broja isporuka
   - za slučaj proizvodnje po narudžbi, manje kompleksnosti i manjeg broja isporuka
   - za slučaj proizvodnje za zalihe, veće kompleksnosti i manjeg broja isporuka
   - za slučaj proizvodnje za zalihe, manje kompleksnosti i većeg broja isporuka
3. **Kraće osnovno plansko razdoblje, u trajanju od 1 mjesec**
   - za slučaj proizvodnje po narudžbi, manje kompleksnosti i većeg broja isporuka
   - za slučaj proizvodnje za zalihe, veće kompleksnosti i većeg broja isporuka
   - za slučaj proizvodnje za zalihe, manje kompleksnosti i manjeg broja isporuka

Nastojeći ograničiti broj tipskih modela proizvodnje-poslovanja, može se reći da u suštini i u najvećem broju, imamo 8 osnovnih modela podijeljenih po parametrima kako slijedi:

1. Način proizvodnje i prodaje	**1.1. za zalihe/kombinirano**
	1.2. po narudžbi
2. Kompleksnost proizvodnje	**2.1. mala**
	2.2. velika
3. Broj isporuka	**3.1. mali**
	3.2. veliki

Kako je već prethodno navedeno, brojna istraživanja u području planiranja i praćenja proizvodnje već su pokazala da ovisno o načinu proizvodnje i prodaje treba koristiti različite modele i metode optimizacije, ovisno da li se radi za zalihe, po narudžbi ili kombinirano. Kako zapravo realno mali broj proizvodnih sustava danas radi isključivo za zalihe, možemo reći da ga zamjenjuje model kombinirane proizvodnje i prodaje.

U proizvodnju po narudžbi ovdje se ne ubraja slučaj pojedinačne proizvodnje kojoj najčešće prethodi niz drugih radnji kao što su projektiranje i dr. pa spada u planiranje i praćenje projekata kao posebne discipline.

Kompleksnost proizvodnje je drugi parametar koji je zajednički izraz za nekoliko parametara kao što su složenost proizvoda, veličina asortimana proizvoda, proizvodni ciklus, složenost proizvodnje-tehnologije, veličina proizvodnih serija i sl. Ti parametri su objedinjeni u jedan jer približno jednako djeluju na modeliranje i izbor planiranja i praćenja.

Sukladno izboru varijante osnovnog planskog razdoblja prema parametrima konkretnog sustava odrediti će se obuhvat planova višeg i nižeg planskog razdoblja u odnosu na osnovno plansko razdoblje, kako je to prikazano na slici 17.

Klizanje u planiranju i praćenju odvija se na način da se prilikom korekcije svakog plana on razrađuje za sljedeće isto razdoblje vremena što znači da će se kod korekcije plana za razdoblje od mjesec dana svakih npr. 7-10 dana razraditi plan za sljedećih mjesec dana, svakih mjesec dana razraditi će se korigirani plan za kvartal-3 mjeseca, a svaki kvartal će se ponovo napraviti plan za razdoblje od 1 godine-12 mjeseci, i tako redom.

Pri tome se korištenjem kliznog planiranja i praćenja ostvaruju dva ključna poboljšanja u odnosu na do sada poznate modele a to sljedeće:

1. Obavlja se moguća i opravdana korekcija aktualnog osnovnog operativnog plana na način da se isti prilagođava zbivanjima u okruženju i samom sustavu
2. Istovremeno se prema promjenama u sustavu i okruženju izvode korekcije, dopune i izmjene sljedećeg višeg plana pa se na taj način dovoljno unaprijed planiraju promjene i prilagodbe za sljedeće duže plansko razdoblje

Prema iskustvima u praktičnom radu nivoe planova i izvještaja možemo podjeliti u grupe s okvirnim vremenskim obuhvatima, kako slijedi:

1. **Dugoročni plan i izvještaj** – najviše plansko razdoblje, obuhvaća više od 5 godina
2. **Srednjeročni plan i izvještaj** – treće više plansko razdoblje, obuhvaća 3-5 godina
3. **Godišnji plan i izvještaj** – drugo više plansko razdoblje, obuhvaća 1 godinu
4. **Periodički plan i izvještaj** – prvo više plansko razdoblje, obuhvaća 3-6 mjeseci
5. **Osnovni plan i izvještaj** – osnovno plansko razdoblje, obuhvaća 1-6 mjeseci
6. **Terminski plan i izvještaj** – prvo niže plansko razdoblje, obuhvaća 7-30 dana
7. **Detaljni plan i izvještaj** – drugo niže plansko razdoblje, obuhvaća 1-7 dana

Pri tome postoje i neki specijalni slučajevi kada se npr. kao osnovno plansko razdoblje odredi razdoblje od 6 mjeseci pa osnovni plan ujedno zamjenjuje periodički plan. Drugi poseban slučaj predstavljaju projekti kao složena, dugotrajna pojedinačna proizvodnja kada se na temelju ukupnog trajanja projekta posebno određuju viša i niža planska razdoblja.

Nivoi planova NP_i i njihov vremenski obuhvat određuju se u nekom proizvodnom sustavu po više varijabli, a što se može prikazati na funkcionalan način prema izrazu (37):

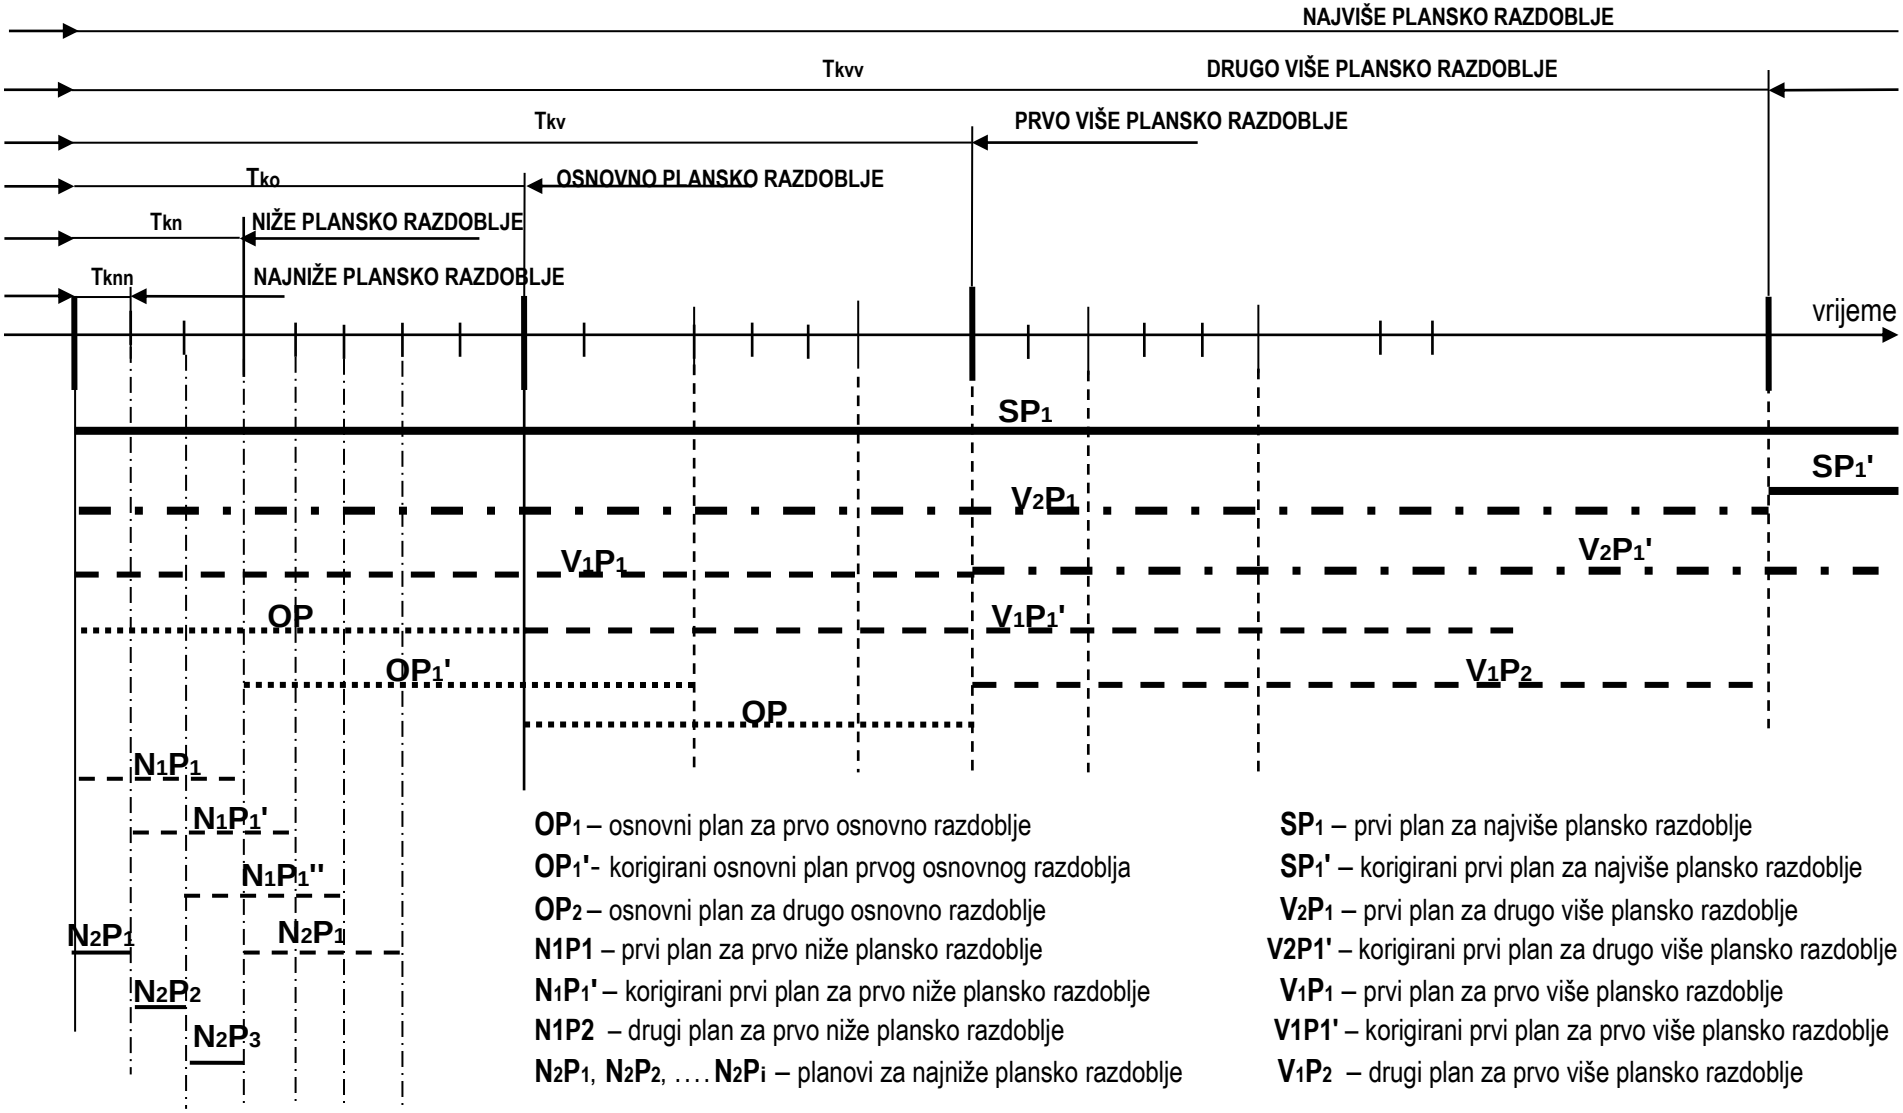

OP1 – osnovni plan za prvo osnovno razdoblje
OP1'- korigirani osnovni plan prvog osnovnog razdoblja
OP2 – osnovni plan za drugo osnovno razdoblje
N1P1 – prvi plan za prvo niže plansko razdoblje
N1P1' – korigirani prvi plan za prvo niže plansko razdoblje
N1P2 – drugi plan za prvo niže plansko razdoblje
N2P1, **N2P2**, …. **N2Pi** – planovi za najniže plansko razdoblje

SP1 – prvi plan za najviše plansko razdoblje
SP1' – korigirani prvi plan za najviše plansko razdoblje
V2P1 – prvi plan za drugo više plansko razdoblje
V2P1' – korigirani prvi plan za drugo više plansko razdoblje
V1P1 – prvi plan za prvo više plansko razdoblje
V1P1' – korigirani prvi plan za prvo više plansko razdoblje
V1P2 – drugi plan za prvo više plansko razdoblje

Slika 17. *Opći shematski prikaz kliznog planiranja i praćenja*

$$NP_i = f\,(x_1, x_2, x_3, x_4, x_5, x_6, x_7, \ldots\ldots x_n) \qquad (37)$$

gdje je: x_1 – veličina sustava po asortimanu i obujmu proizvodnje,

x_2 – broj dijelova sustava i povezanih sustava,

x_3 – broj klijenata-kupaca,

x_4 – broj i dinamika promjena u okruženju i sustavu,

x_5 – složenost proizvoda i tehnologije,

x_6 – dužina ciklusa proizvodnje,

x_7 – nivo informacijskog procesa, ...

x_n – drugi relevantni parametri

Ovdje neće biti moguće preciznije definirati nivoe planova NP_i, ali se može naznačiti u kojem smislu će navedene varijable djelovati na njihovo određivanje.

Veličina proizvodnog sustava po asortimanu proizvoda i obujmu proizvodnje x_1 tražiti će da sustav ima planove za kraća razdoblja zbog velike vjerojatnosti pojave odstupanja i poremećaja u realizaciji. Isto se može očekivati ako poslovni sustav ima veći broj dijelova i povezanih sustava x_2, veći broj klijenata-kupaca x_3 te veći broj i dinamiku promjena u sustavu i njegovom okruženju x_4.

S druge strane, u slučaju proizvodnje složenijih proizvoda i korištenja složenijih tehnologija x_5, dužih proizvodnih ciklusa proizvodnje x_6 i naprednijeg informacijskog sustva x_7 može se pretpostaviti da će sustav imati planove za duža vremenska razdoblja. Na to mogu utjecati i neki drugi relevantni parametri x_n procijenjeni kao značajni.

Teoretski gledano, idealan slučaj za proizvodnju bi bila kontinuirana proizvodnja jednog proizvoda za jednog kupca, praktično bez korekcija plana, a najnepovoljniji bi bio slučaj proizvodnje velikog broja proizvoda za veliki broj kupaca, s velikim brojem promjena i poremećaja koji bi možda praktično tražio da se gotovo svakodnevno obavljaju korekcije planova, pa se postavlja pitanje intenziteta klizanja planiranja i praćenja, odnosno korekcija planova.

Intenzitet klizanja planiranja i praćenja, odnosno vrijeme između dvije korekcije planova poseban je problem i dio je optimizacije procesa planiranja i praćenja. On se može odrediti prema intenzitetu promjena i poremećaja u sustavu i njegovom okruženju te sukladno nivoima planova NP_i određenim prema funkcionalnim odnosima po izrazu (37). Stoga se može reći da za određivanje intenziteta kliznog planiranja i praćenja K_i vrijedi izraz (38)

$$K_i = NP_i / NP_{i-1} \quad (38)$$

gdje je: NP_i – nivo, razdoblje tretiranog plana

NP_{i-1} – nivo, razdoblje prvog nižeg plana

Važno je napomenuti da je K_i uvijek cijeli broj ali koji ne mora biti isti za svaki nivo plana već će ovisiti o parametrima, odnosno varijablama utvrđenim u izrazu (37). U specijalnim slučajevima razdoblja korekcije nekog nivoa plana ne moraju u promatranom periodu biti identična već se mogu i međusobno razlikovati ako se radi o specijalnim poremećajima ili promjenama u okruženju ili samom sustavu. No, poželjno je da interval između dvije korekcije nekog niova plana bude po mogućnosti isti zbog kontinuiteta u radu, praćenja i obrade rezultata planiranja i praćenja.

Obzirom na tromost proizvodnog sustava, poželjno je da se klizanje u planiranju i praćenju obavlja što rjeđe, u pravilnim vremenskim razmacima pa bi s obzirom na procjenjena osnovna planska razdoblja bilo za očekivati da bi se intenzitet klizanja planiranja i praćenja mogao odvijati kako je to prikazano na slikama 18., 19. i 20. za svako osnovno plansko razdoblje, gdje je:

- **OPd** – plan za duže osnovno razdoblje
- **OPs** – plan za srednje osnovno razdoblje
- **OPk** – plan za kraće osnovno razdoblje
- **(OP)i'** – prvi korigirani plan za osnovno razdoblje s intenzivnijim kliznim planiranjem
- **(OP)i''** –drugi korigirani plan za osnovno razdoblje s intenzivnijim kliznim planiranjem
- **(OP)r'** – prvi korigirani plan za osnovno razdoblje sa rjeđim kliznim planiranjem
- **(OP)r''** – drugi korigirani plan za osnovno razdoblje sa rjeđim kliznim planiranjem
- $(T_k)_i$ – vrijeme korekcije plana kod intenzivnijeg kliznog planiranja
- $(T_k)_s$ – vrijeme korekcije plana kod rjeđeg kliznog planiranja

Za svaku varijantu osnovnog planskog razdoblja broj korekcija osnovnog plana biti će za jedan manje nego što je to omjer osnovnog planskog razdoblja i vremena korekcije, jer će se za sljedeće kalendarsko razdoblje u dužini osnovnog planskog razdoblja taj plan ponovo zvati osnovni plan.

Istom logikom će se obavljati klizno planiranje za ostale planove višeg i nižeg planskog razdoblja u odnosu na osnovno plansko razdoblje, kako je to dijelom prikazano na slici 17.

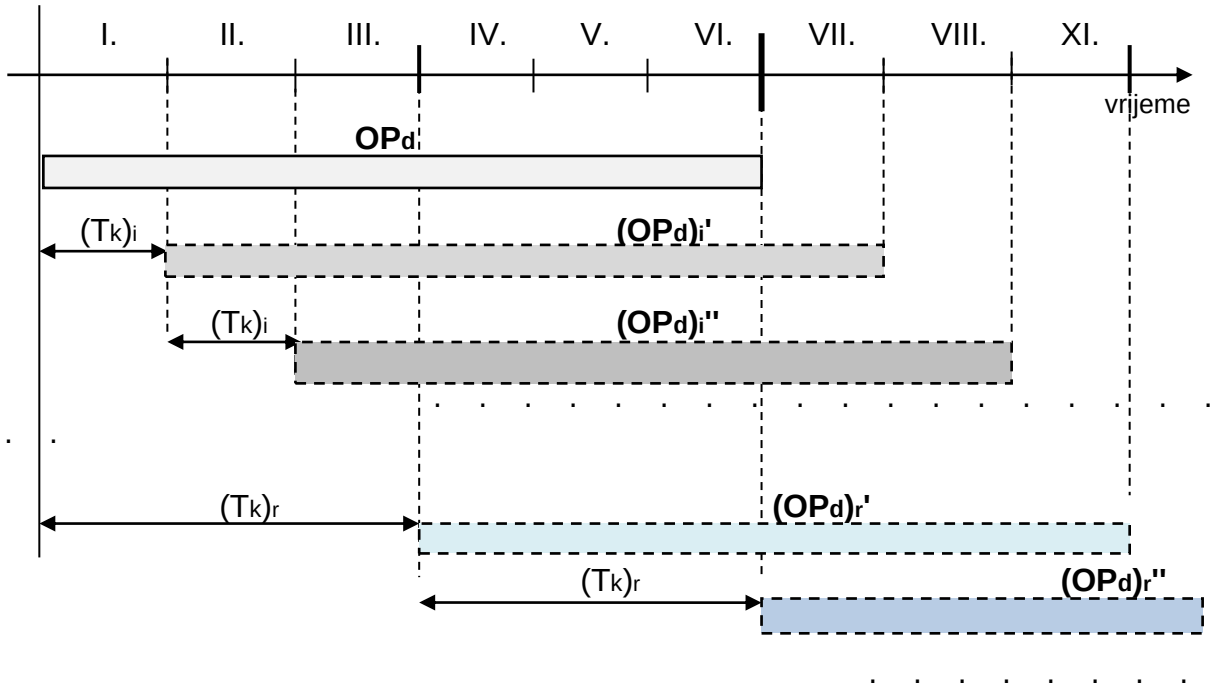

Slika 18. *Klizno planiranje i praćenja za duže osnovno plansko razdoblje*

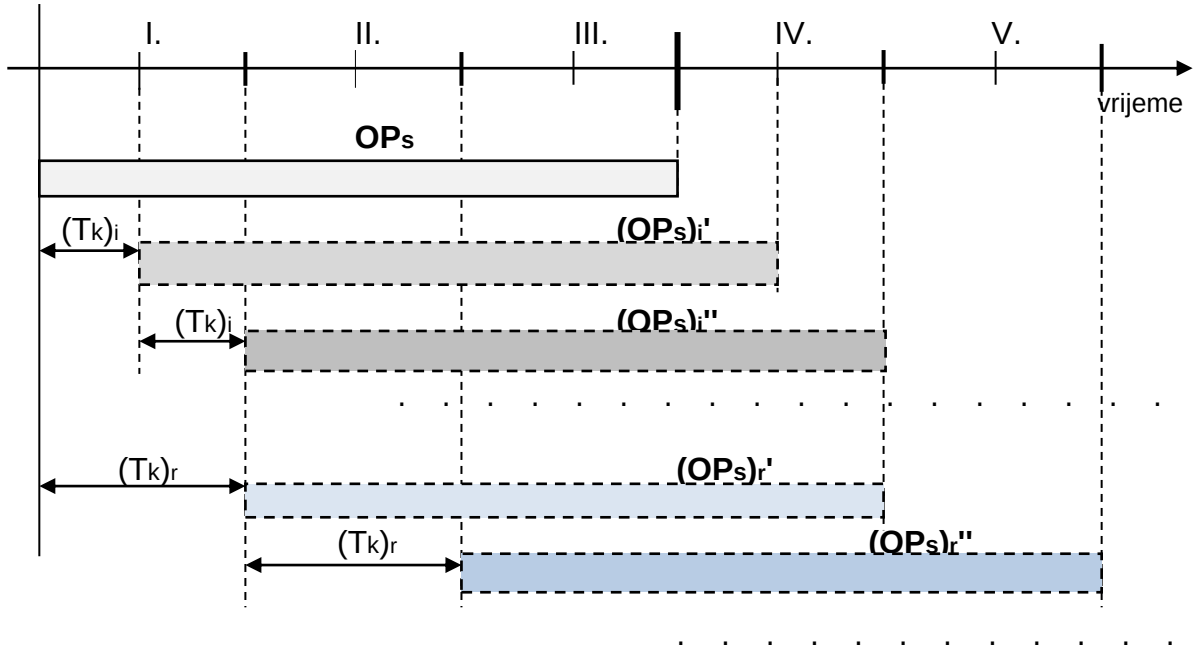

Slika 19. *Klizno planiranje i praćenja za srednje osnovno plansko razdoblje*

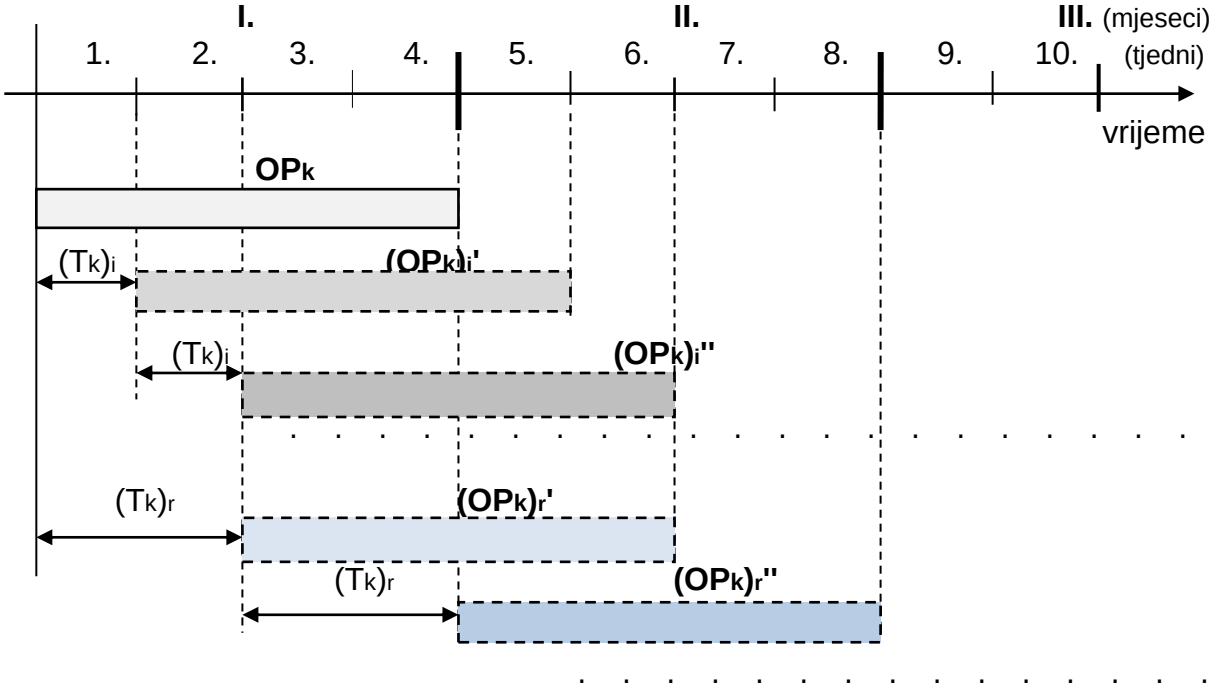

Slika 20. *Klizno planiranje i praćenja za kraće osnovno plansko razdoblje*

Naravno da je moguće u nekim konkretnim proizvodnim sustavima odabrati i neke druge varijante osnovnog planskog razdoblja, a samim time i dinamiku klizanja koja u suštini i ne mora biti u jednakim vremenskim razmacima. Međutim, svakako treba tražiti objektivni kompromis između stabilnosti proizvodnog procesa i prilagodljivosti proizvodnog sustava promjenama u okruženju.

No, u svakom slučaju prilikom donošenja odluka o izboru modela kliznog planiranja i praćenja i njegovog intenziteta odvijanja za tretirani proizvodni sustav, detaljno treba razmotriti funkcionalne odnose svih neposrednih procesa vezanih za planiranje i praćenje, prema izrazu (39)

$$IPP = f\,(P_{pr}, P_p, P_n, P_{pp}) \qquad (39)$$

gdje je: IPP – intenzitet kliznog planiranja i praćenja

P_{pr} - pouzdanost proizvodnje (strojeva, izvršilaca, kooperanata i dr.)

P_p - pouzdanost prodaje (poznavanje tržišta prodaje po količinama i rokovima)

P_n - pouzdanost nabave (poznavanje tržišta nabave po količinama i rokovima)

P_{pp} - pouzdanost planiranja i praćenja (znanja, tehnike, pomagala, kontrola rizika)

Svaka od navedenih varijabli je složena, ima svoje zakonitosti i parametre koji se razlikuju u svakom sustavu i mijenjanju se tijekom vremena, a posebno one informacije i zakonitosti koje su vezane za okruženje sustava. Obzirom na značaj i utjecaj pouzdanosti navedenih procesa nameće se važnost procesa planiranja i praćenja kao glavnog dijela operativnog upravljanja proizvodnjom. Samo kroz njihovu povezanost i međusobno djelovanje rasti će pouzdanost svakog od procesa pa se time povećava uspješnost i planiranja i praćenja, kao i sustava u cjelini. Što će se više (pouzdanije) pribavljati pravovremene i cjelovite informacije o promjenama u okruženju i istovremeno u te procese vezane s okruženjem davati povratne informacije o realizaciji i raspoloživosti kapaciteta, moći će se kvalitetnije planirati i realizirati planovi sustava.

Kako je intenzitet planiranja i praćenja dio optimizacije tog procesa i njegovih sadržaja-planova, isti se detaljnije obrađuje u nastavku ovog rada.

6.5. Optimizacija prilagodljivog planiranja i praćenja

Klizno planiranje i praćenje povezano s nekom od metoda i tehnika programiranja proizvodnje trebao bi biti model prilagodljivog planiranja i praćenja proizvodnje kojim bi se omogućilo iznalaženje optimalnih planova i optimalnog procesa planiranja i praćenja. To treba biti na način da se u što većoj mjeri uzimaju u tretman promjene, poremećaji i rizici u sustavu i njegovom okruženju i optimiraju rješenja za takve situacije uz osiguranje prilagodljivosti i fleksibilnosti proizvodnog sustava. Drugim riječima, traži se model planiranja i praćenja koji se može u što većoj mjeri prilagoditi stvarnim, aktualnim uvjetima u sustavu i njegovom okruženju na optimalan način. Naime, u praksi se uvijek događaju manji ili veći poremećaji i promjene zbog kojih dolazi do odstupanja realizacije u odnosu na optimalno planirane rezultate, a standardne metode i tehnike optimizacije nisu oblikovane na način koji omogućuje prilagodljivost i fleksibilnost proizvodnog sustava.

Da bi se kreirao model optimizacije planiranja i praćenja potrebno je znati po kojim će se kriterijima i mjerilima vršiti optimizacija. U poglavlju 3.2. naveden je veći broj kriterija i mjerila kojima se autori koriste u modelima optimizacije planova i tu se vidi da se uglavnom koriste pojedinačni kriteriji, sukladno postavljenim ciljevima tretiranog sustava, odnosno tipa proizvodnje i postojećim uvjetima njihovog djelovanja. Korištenje pojedinačnih kriterija olakšava primjenu matematičkih metoda i tehnika optimizacije, ali pokazuje da će se za različite kriterije optimizacije dobiti različiti rezultati.

To ukazuje na potrebu korištenja sintetskih kriterija sastavljenih po odgovarajućem algoritmu od nekoliko pojedinačnih kriterija pri čemu se može preporučiti da se sintetski kriteriji optimizacije sastoje od 2-4 pojedinačna kriterija.

Pri tome ne treba zaboraviti ni kriterije i mjerila za ocjenjivanje uspješnosti planiranja i praćenja, pogotovo iz razloga što su vrlo česta odstupanja realizacije u odnosu na optimalno postavljene planove, posebno u uvjetima većih i iznenadnih promjena u okruženju.

Svaki proizvodni sustav ima za cilj ostvariti što profitabilniju proizvodnju i poslovanje, tj. što veću razliku prihoda i troškova i istovremeno to realizirati uz što veći obujam proizvodnje, odnosno prihod, a time bolju iskoristivost kapaciteta, što podrazumijeva i veće zadovoljenje potreba tržišta. Sa tako postavljenim ciljevima kao relativno jednostavno rješenje nameće se sintetski kriterij uspješnost proizvodnje-poslovanja UP definiran prema izrazu (40)

$$UP = IK \cdot PF \tag{40}$$

gdje je: IK – iskoristivost kapaciteta (mjereno u decimalnom iskazu postotka)

PF – profitna stopa (mjereno u decimalnom iskazu postotka)

Na ovaj se način kombiniraju financijski i materijalni kriterij jer iskoristivost kapaciteta IK indirektno pokazuje koliki se obujam proizvodnje kao prihod ostvaruje na tržištu te koliko se racionalno razvijaju proizvodni kapaciteti. Profitna stopa govori o odnosu prihoda i troškova pa se na taj način vidi koliko je proizvodni sustav poslovno i financijski uspješan.

Osim toga, poznato je da veće i kontinuirano korištenje kapaciteta omogućava veću stabilnost i pouzdanost proizvodnje što podrazumijeva i manju vjerojatnost pada kvalitete proizvoda, a smanjuju se i troškovi proizvodnje te se bolje amortiziraju strojevi i oprema. Uz navedeno, potrebno je napomenuti da se pod pojmom kapaciteta podrazumijevaju svi raspoloživi kapacitet kojima proizvodni sustav raspolaže ili ga koristi kod trećih.

Kako je već na početku istraživanja predložen model optimizacije proizvodnje, sigurno je da kao metodu i tehniku optimiranja u procesu planiranja i praćenja treba koristiti neku od matematičkih modela dinamičkog programiranja jer je za probleme planiranja i praćenja vrijeme važan faktor.

Dinamičko programiranje kao dio matematičkog programiranja je metoda i tehnika optimizacije rješenja kod kojih je vrijeme važan faktor, a zahtijeva se upravljanje procesom koje je postupno i sprovodi se za više razdoblja, u više etapa, na način da se optimizacija planiranja za veći broj razdoblja-etapa odvija u nekoliko koraka koji prethode cilju.

Ako pokazatelj Φ uzmemo kao kriterij dinamičkog programiranja proizvodnje sustava S za neko razdoblje T i ako se sustavom upravlja tijekom vremena putem rješenja U, postavlja se problem izbora Ut po razdobljima t kako bi se postigao maksimum ili minimum od Φ.

U slučaju planiranja, to znači određivanje planova $P_1, P_2, \ldots P_k$ za vremensko razdoblje T koje se sastoji od m razdoblja-etapa. Ako je x_{ij} rješenje za i-to razdoblje i plan P_i, onda je vektor u izrazu (41) rješenje Pi.

$$\overrightarrow{X_{(ij)}} = (x_{i1}, x_{i2}, \ldots\ldots\ldots x_{ik}) \tag{41}$$

Vektori $\overrightarrow{X_1}$, $\overrightarrow{X_2}$, $\ldots\ldots\ldots \overrightarrow{X_k}$ odgovaraju skupu rješenja $U_1, U_2, \ldots\ldots U_k$ definiraju funkciju Φ koju treba maksimizirati ili minimizirati, prema izrazu (42)

$$\Phi = \Phi\,(U_1, U_2, \ldots\ldots U_k) \tag{42}$$

Promatrajući proizvodni sustav *S*, od svih mogućih stanja S_t po razdobljima *t* treba obratiti pažnju na početno $S_{poč.}$ i krajnje stanje $S_{kraj.}$ pri čemu za svako, i na početku i na kraju ima više mogućnosti, kako je to prikazano na slici 21. Zadatak je dinamičkog programiranja pronaći iz skupa rješenja *U* optimalno rješenje *U** koje sustav *S* iz početnog uvjeta $S^{(0)}$ u etapama, po razdobljima, prevodi do konačnog rješenja $S^{(n)}_{kraj.}$ tako da se *Φ* optimizira.

U suštini dinamičko programiranje predstavlja etapno upravljanje, odnosno rješavanje zadatka pri čemu u svakoj etapi-razdoblju treba donijeti odgovarajuće odluke. One u suštini ne moraju u svakoj etapi biti optimalne već je cilj na cjelovitoj optimalnosti ukupno tretiranog vremenskog razdoblja. Optimalnost zadnjeg koraka, kao zadnja etapa u donošenju odluka zasniva na pretposljednjoj odluci, ova na prethodnoj i td., pa to predstavlja uvjetni optimum.

Pri izvođenju *k*-tog koraka operacije korak (*k-1*) je neizvjestan i u toj etapi se predpostavlja čitav niz rješenja označenih prema izrazu (43)

$$S^{(1)}_{k-1}; \quad S^{(2)}_{k-1}; \quad \ldots\ldots\ldots; \quad S^{(j)}_{k-1} \tag{43}$$

Za svako rješenje iz izraza (43) treba odrediti odluku u *k*-tom koraku U_k pa ona postaje jedna od sljedećih odluka po izrazu (44)

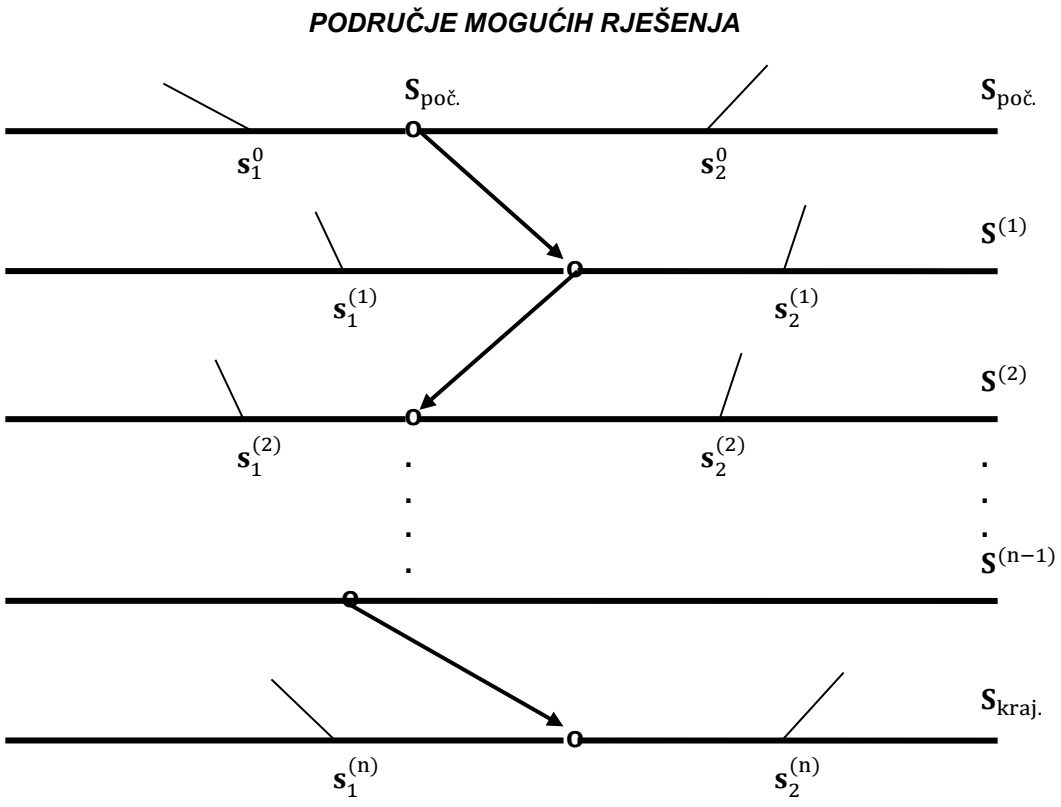

Slika 21. *Shematski prikaz opće postavke dinamičkog programiranja*

$$U_k(S_{k-1}^{(1)}); \quad U_k(S_{k-1}^{(2)}); \quad \ldots\ldots\ldots; \quad U_k(S_{k-1}^{(j)}) \tag{44}$$

Sada svako rješenje $S_{k-1}^{(j)}$ ovisi o rješenju u (k-2)-tom koraku pri čemu su u tom koraku moguća rješenja dana u izrazu (45)

$$S_{k-2}^{(1)}; \quad S_{k-2}^{(2)}; \quad \ldots\ldots\ldots; \quad S_{k-2}^{(j)} \tag{45}$$

pa odluku U_{k-1} prema izrazu (45) treba tražiti u nizu prikazanom u izrazu (46)

$$U_{k-1}(S_{k-2}^{(1)}); \quad U_{k-1}(S_{k-2}^{(2)}); \quad \ldots\ldots\ldots; \quad U_{k-1}(S_{k-2}^{(j)}) \tag{46}$$

Ako se tako nastavi dalje, dolazi se do prvog koraka čijom se odlukom, odnosno rješenjem dolazi do optimalnog ukupnog rješenja.

No, postoji problem nedostatka odgovarajućeg algoritma za dinamičko programiranje koje se bez uspjeha pokušava naći već nekoliko desetljeća pa se u suštini, u praktičnoj primjeni dinamičko programiranje određenim postupcima svodi na linearno programiranje.

Jedan od način dobivanja dinamičnosti u programiranju planova proizvodnje u smislu prilagodljivosti je primjena kliznog planiranja i praćenja uz korištenje metoda linearnog programiranja i takav model se može nazvati **dinamizirano programiranje** čiji je shematski prikaz dat na slici 22.

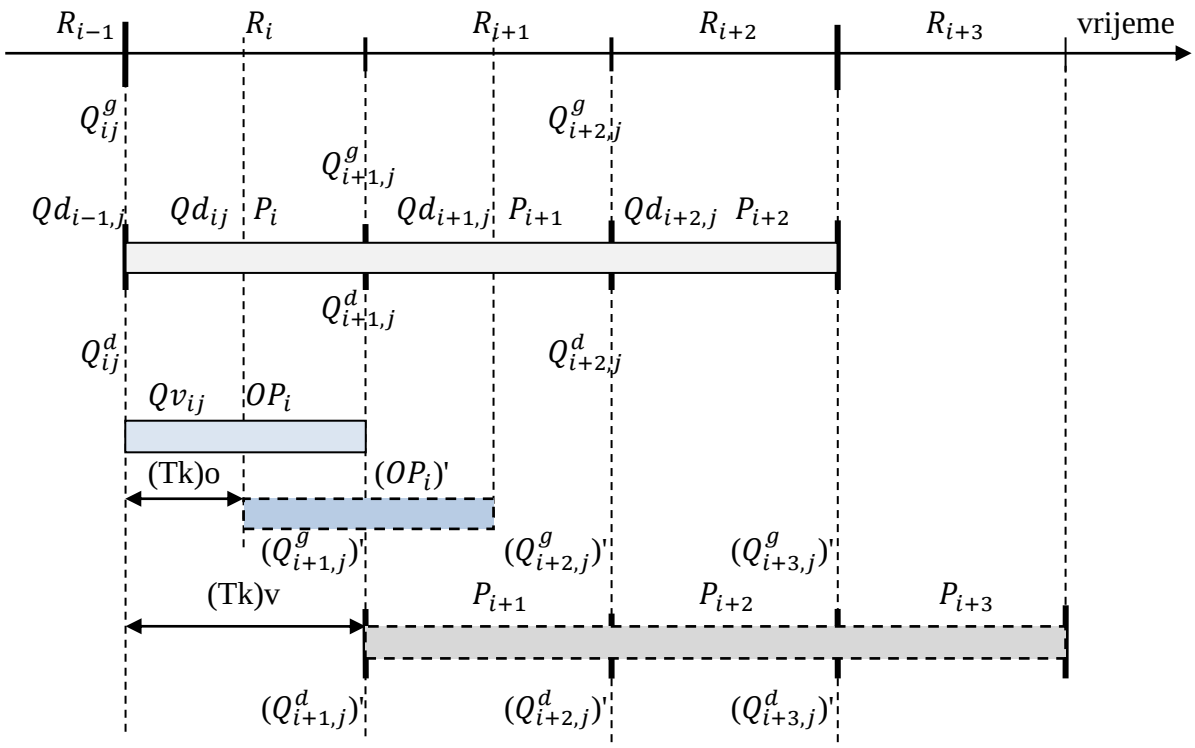

Slika 22. *Shematski prikaz modela dinamiziranog programiranja*

Kod modela dinamiziranog programiranja, za primjer u slučaju kada je osnovni plan mjesečni a prvi viši plan kvartalni, optimiziraju se tri mjesečna plana jednog kvartala P_i, P_{i+1} i P_{i+2} putem linearnog programiranja sukladno gornjim i donjim granicama potražnje Q_{ij}^{g} i Q_{ij}^{d}, $Q_{i+1,j}^{g}$ i $Q_{i+1,j}^{d}$ te $Q_{i+2,j}^{g}$ i $Q_{i+2,j}^{d}$, kao i ograničenjima ostalih resursa relevantnih za programiranje i optimiranje planova.

Istekom razdoblja korekcije višeg plana (Tk)v ponovno se vrši programiranje tri plana za sljedeća tri dijela kvartala R_{i+1}, R_{i+2} i R_{i+3} uz korigirane granice potražnje $(Q_{i+1,j}^{g})'$ i $(Q_{i+1,j}^{d})'$, $(Q_{i+2,j}^{g})'$ i $(Q_{i+2,j}^{d})'$ te $(Q_{i+3,j}^{g})'$i $(Q_{i+3,j}^{d})'$. Korekcija tih granica napravljena je prema očekivanim dodatnim narudžbama dobivenih u prethodnim razdobljima Qd_{ij}, $Qd_{i-1,j}$ itd., a u skladu s ostalim raspoloživim resursima. Analogno se postupa kada se narudžbe otkazuju ili se zbog poremećaja u raspoloživosti resursa smanjuju planovi realizacije.

Kada se u navedeni model dinamiziranog programiranja želi uključiti i optimalno rješavanje situacija promjena i poremećaja po pojedinim dijelova razdoblja za koje je prethodno dato najpovoljnije rješenje, može se ili ponovno tretirati odabrano plansko razdoblje od momenta donošenja odluke o istom ili oponašanjem odrediti rješenje korekcije postojećeg plana.

Ako se korekcija operativnog plana OP_i obavlja istekom razdoblja korekcije $(T_k)_o$, tada se putem oponašanja utvrđuje koji se dio neočekivanih dodatnih narudžbi Qv_{ij} može realizirati u tekućem operativnom razdoblju pa se dobiva korigirani operativni plan $(OP_i)'$.

U slučaju kad bi se kod svake značajnije promjene ili poremećaja ponovno obavljala optimizacija planova za odabrano razdoblje putem dinamičkog programiranja, vrlo je vjerojatno da bi pri tome imali sljedeće poteškoće:

a. promjene u redosljedu realizacije serija-narudžbi sa fiksnim rokovima isporuke
b. promjene u planovima nabave materijala
c. preraspoređivanje izvođenja tehnoloških operacija po strojevima za planirane proizvode u tijeku njihove realizacije

Sve to u znatnoj mjeri može otežati realizaciju proizvodnje te izazvati dodatne troškove i aktivnosti, posebno u procesu planiranja i praćenja, pa se iskazuje potreba izbora i oblikovanja modela koji može biti primjenjiv u većem broju tipova i uvjeta proizvodnje.

Takav model korektivne optimizacije kojim se uz primjenu oponašanja i postupka kliznog planiranja i praćenja korigiraju planovi dobiveni metodom dinamiziranog programiranja nazvan je **diskretno korektivno dinamizirano optimiranje**.

No, prije samog oblikovanja modela diskretnog korektivnog dinamiziranog optimiranja potrebno je odrediti kriterije i mjerila za određivanje optimalne korekcije planova koji će s jedne strane biti u skladu sa postojećim, odabranim kriterijima za dinamizirano programiranje a s druge strane s obzirom na to kada je i kakva optimalna korekcija planova moguća.

Najpovoljnija, optimalna korekcija nekog operativnog plana biti će ona korekcija kod koje će se ostvariti najveća razlika porasta prihoda i profita u odnosu na dodatne troškove planiranja i praćenja, kako slijedi prema izrazu (47)

$$EK = IPP - PT \tag{47}$$

gdje je: EK - efikasnost korekcije plana

PT - promjena troškova

IPP - indeks promjene prihoda IP i profita IF, prema izrazu (48)

$$IPP = IP \cdot IF \tag{48}$$

Promjena troškova PT uzima se u mjerilu decimalnog iskaza postotka promjene troškova u odnosu na troškove kod postojećeg plana, a promjena prihoda IP i profita IF, kao i njihov umnožak prema izrazu (48) iskazuje se kao indeks, odnosno kao decimalni iskaz postotka promjene uvećan za 1, pa na taj način imamo da je uvijek IPP > PT, zbog lakšeg operiranja.

Indeks promjene prihoda i profita IPP pokazuje koliko se može povećati efikasnost polaznog, osnovnog plana kao pokazatelj prilagodljivosti i fleksibilnosti proizvodnog sustava prema promjenama na tržištu. Logično je da svaki proizvodni sustav želi svako povećanje potražnje iskoristiti kako u smislu poboljšanja poslovnog rezultata tako i u smislu zadovoljenja potreba tržišta. Istovremeno se to nastoji postići uz minimalno povećanje troškova planiranja i praćenja koji obuhvaćaju više stavki kao što su neposredni troškovi planiranja i praćenja, troškovi povećanja zaliha proizvoda i sirovina, troškovi dodatnih kapaciteta i rada i sl.

No, indeks promjene prihoda i profita IPP može poprimiti i vrijednosti manje od 1, kao što promjena troškova PT može imati negativnu vrijednost jer promjene i poremećaji u okruženju i sustavu mogu biti pozitivnog i negativnog karaktera, kako slijedi:

a. povećavanje potražnje na tržištu, i rast prihoda, sa povećanjem ili smanjenjem profitabilnosti te manjim ili većim porastom troškova planiranja i praćenja
b. smanjenje potražnje–otkazivanje narudžbi proizvoda ili poremećaji u proizvodnji i nabavi materijala s padom prihoda te promjenom profitabilnosti troškova planiranja

Promjene i poremećaji se prikupljaju i obrađuju u svakom razdoblju korekcije $(T_k)_i$ osnovnog plana, a njegove provjere i korekcije vrše se pravilno, za svako razdoblje korekcije.

U tu se svrhu koristi metoda oponašanja kako bi se od svih realno mogućih varijanti korekcije plana odabrala ona kod koje je efikasnost korekcije EK maksimalna, kako je to prikazano na slici 23. Kao varijante korekcije polaznog osnovnog plana uzimaju se samo one koje je moguće realizirati u razdoblju sljedećeg korigiranog osnovnog plana. Stoga se promjene u okruženju koje nije moguće tretirati u tom razdoblju prebacuju za obradu u naredno razdoblje korekcije ili se ostavljaju za razmatranje u izradi sljedećeg polaznog osnovnog plana ili korekcije polaznog prvog višeg plana.

U slučaju velikog asortimana proizvoda morati će se izraditi veći broj mogućih varijanti rješenja korekcije operativnog plana i po prethodno navedenom kriteriju odrediti će se najbolja moguća korekcija plana. Pod mogućim varijantama korekcije planova podrazumijevaju se ona riješenja za koja postoje ili se odmah mogu osigurati potrebni resursi i kod kojih će se lansiranje novih narudžbi u proizvodnju vršiti uz eventualne promjene mjesta i termina rada već lansiranih radnih naloga samo u okviru njihovih zadanih rokova.

To je u svakom slučaju objektivnije rješenje, a pogotovo stoga što se u slučaju računalne optimizacije u okviru svih mogućih teoretskih rješenja može dogoditi da računalo ne može završiti s radom i pronaći teoretsko optimalno rješenje.

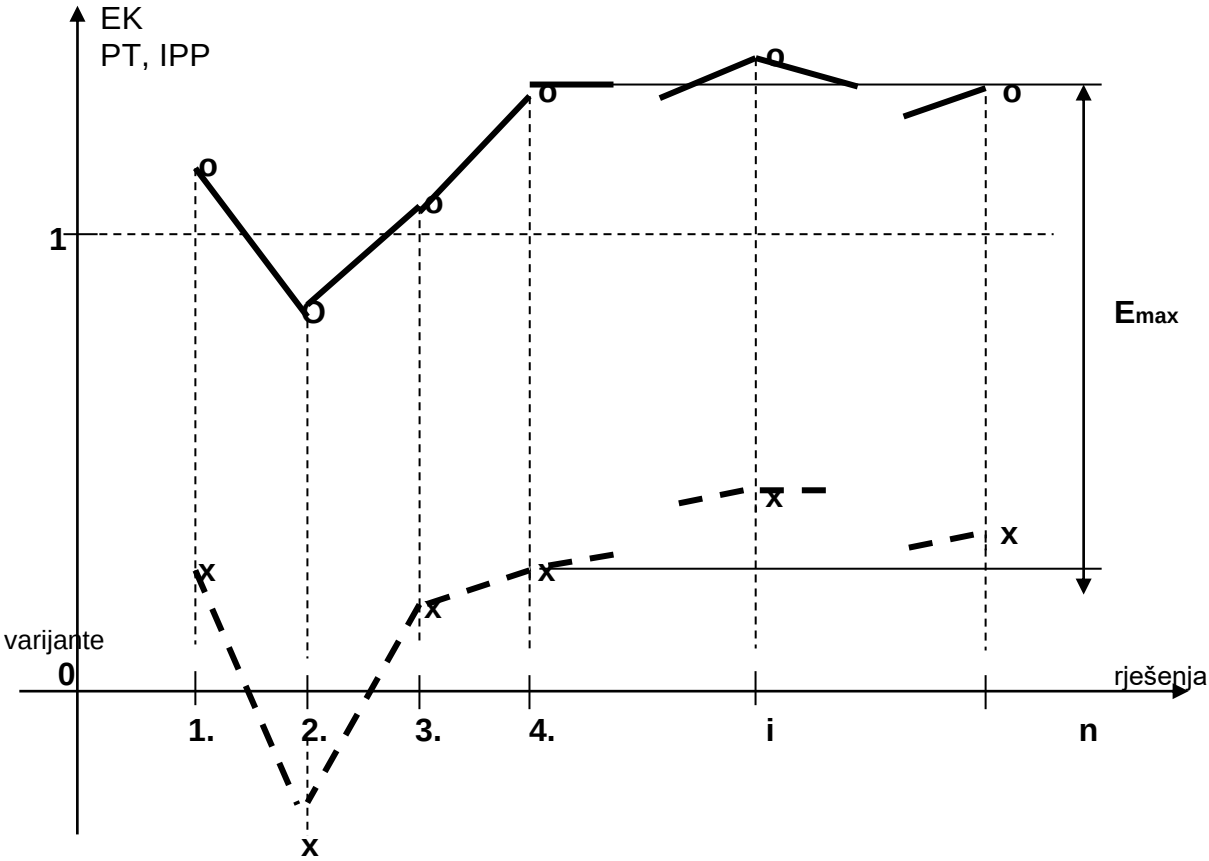

Slika 23. *Određivanje optimalne varijante korekcije osnovnog plana*

Diskretno korektivno dinamizirano optimiranje omogućava da se proizvodni sustav u maksimalno mogućoj mjeri prilagođava promjenama i poremećajima u okruženju i samom sustavu na način da u slučaju pozitivnih promjena, odnosno porasta potražnje za gotovim proizvodima, maksimalno povećava svoju uspješnost proizvodnje UP (40).

U slučaju negativnih promjena i poremećaja – kašnjenja u dobavi materijala, kvara strojeva i sl., minimiziraju se odstupanja od prethodno utvrđenog optimuma uspješnosti proizvodnje UP a da se pri tome u najmanjoj mogućoj mjeri remeti ritam proizvodnje.

Na slici 24. dat je shematski prikaz diskretnog korektivnog dinamiziranog optimiranja za slučaj kada se osnovni plan radi za razdoblje od mjesec dana, a tjedan je razdoblje korekcije osnovnog plana dok je prvi viši plan kvartalni plan s razdobljem korekcije od mjesec dana.

Pri tome je uvijek polazni osnovni plan prvi dio aktualnog kvartalnog plana, bez obzira da je taj plan polazni ili korigirani, koji se uvijek određuje dinamiziranim programiranjem dok se korekcije osnovnog plana obavljaju primjenom metode i tehnike oponašanja.

Za odabrani primjer diskretnog korektivnog dinamiziranog optimiranja na slici 24. pretpostavljene su 4 općenite grupe promjena koje se mogu dogoditi u razdoblju korekcije osnovnog plana a koje mogu djelovati pozitivno ili negativno, i to:

a. veći broj većih promjena
b. veći broj manjih promjena
c. manji broj većih promjena
d. manji broj manjih promjena

O istom je potrebno voditi računa jer se navedene vrste promjena ne mogu uvijek tretirati na jednak način i mora ih se, obzirom na njihovu veličinu i karakter, sortirati prema razdoblju u koje mogu biti uključene u tretman. Tako se neke mogu ili moraju tretirati već pri prvoj sljedećoj korekciji osnovnog plana tražeći optimalno rješenje za korigirani osnovni plan putem oponašanja dok će se neke tretirati tek kod korekcije prvog višeg plana.

U shematskom prikazu na slici 24. za svaki skup promjena P_{ij} koji se pojavi u najkraćem razdoblju korekcije T_k prvo je potrebno selekcionirati karakter svake prispjele informacije o promjeni. Karakter informacije će biti pozitivan ako se radi o potražnji proizvoda a negativan kada se radi o poremećaju u dobavi repromaterijala, korištenju energenata ili smanjenju kapaciteta zbog kvara ili problema kod kooperanta.

Ako informacija o promjeni ima negativan karakter, ona će se uzimati u tretman kod prve sljedeće korekcije aktualnog plana, a ako je njen karakter pozitivan, informacija će se razvrstati u odgovarajuće razdoblje osnovnog plana - mjesečno razdoblje. Aktualnost pozitivne informacije određuje se prema zahtijevanom, predviđenom roku njene realizacije.

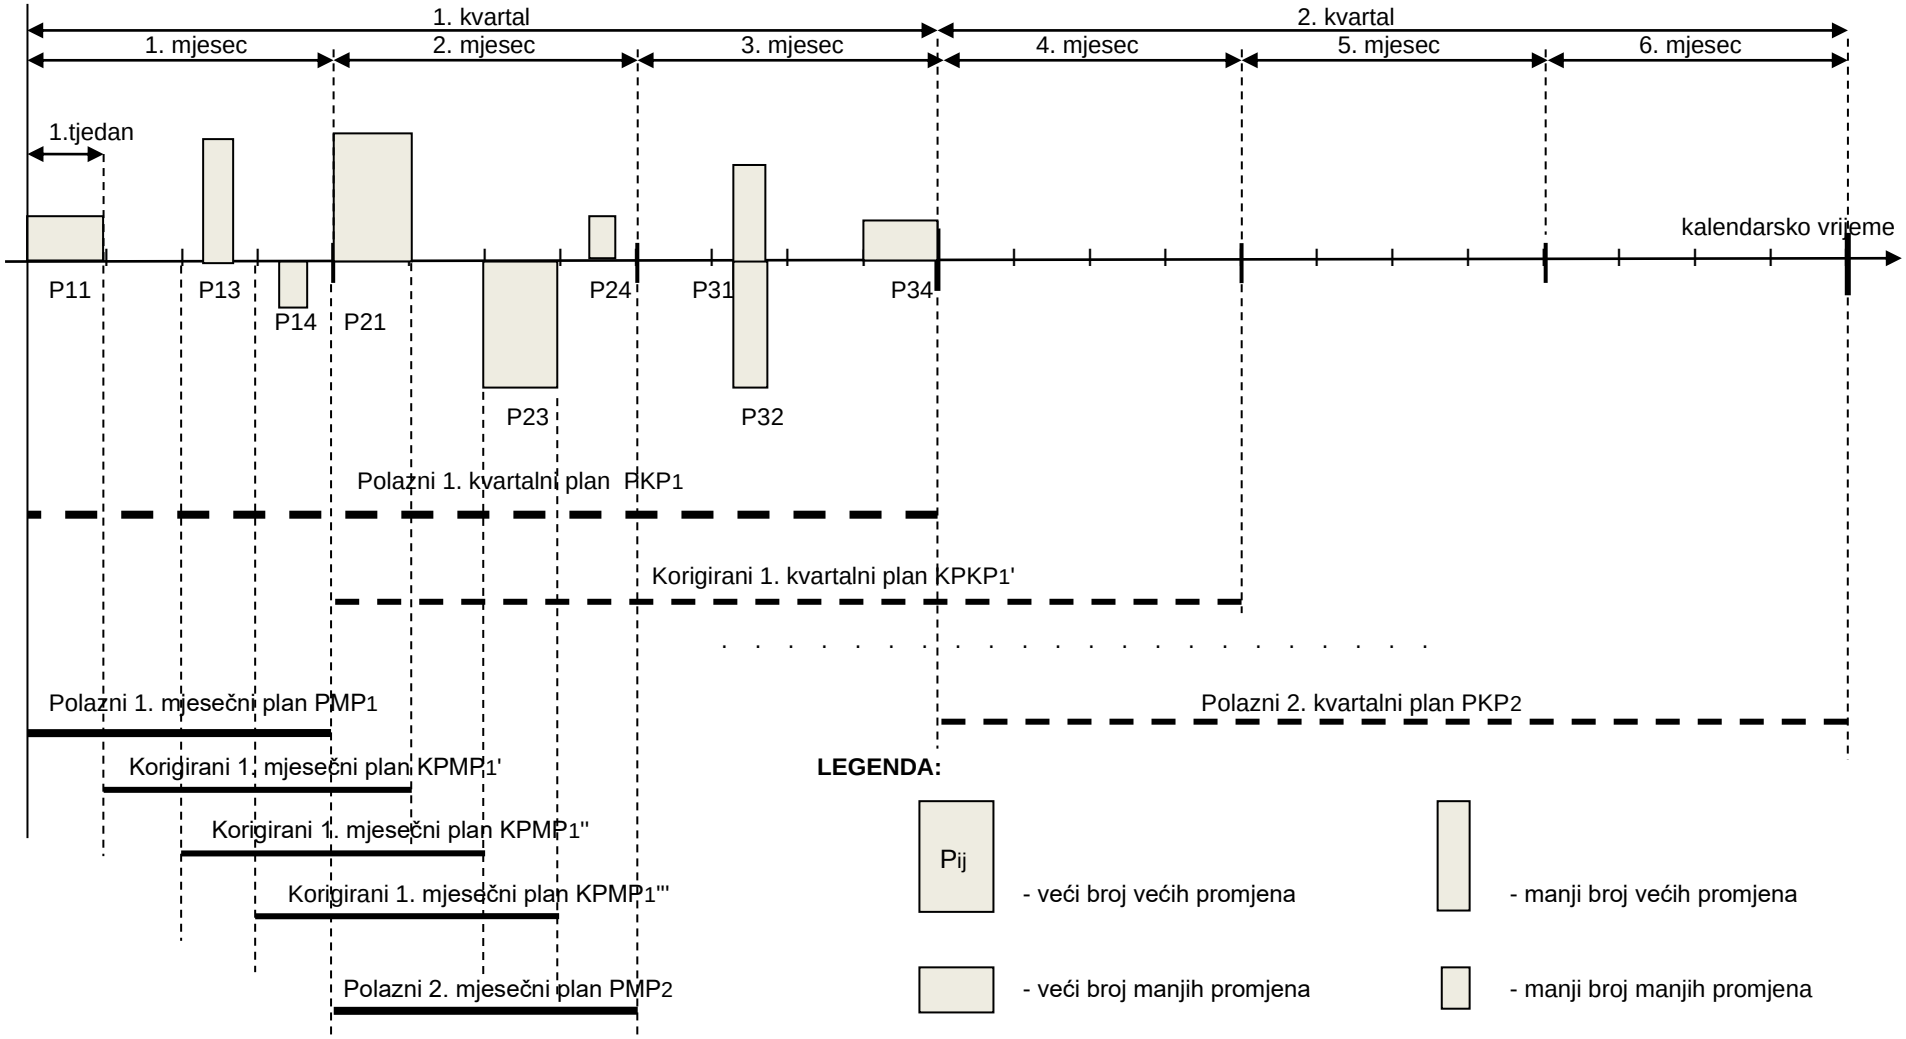

Slika 24. *Shematski prikaz diskretnog korektivnog dinamiziranog optimiranja*

Tako razvrstane informacije o promjenama obrađivati će se kako slijedi:

a. sve aktualne informacije iz prvog najkraćeg razdoblja korekcije T_k koristiti će se za prvu korekciju osnovnog plana $KPMP_1'$ čija će se optimizacija obaviti oponašanjem
b. za izvođenje optimizacije prvog korigiranog osnovnog plana $KPMP_1'$ odrediti će se njegove moguće varijante i između njih odabrati najpovoljnija, odnosno optimalna
c. ostale informacije o promjenama tretirati će se na isti način kod svake sljedeće korekcije osnovnog plana, sukladno njihovoj aktualnosti
d. informacije o promjenama koje su aktualne za razdoblje drugog osnovnog plana će se tretirati u sklopu korekcije prvog višeg plana, u ovom slučaju kvartalnog, $KPKP_1'$
e. korigirani prvi viši plana, a isto tako i ostali viši planovi, određivati će se po svojim dijelovima putem dinamiziranog programiranja na prethodno opisani način

Bez obzira što se na primjeru na slici 24. npr. u drugom tjednu, odnosno razdoblju korekcije nisu dogodile nikave promjene, potrebno je izraditi drugu korekciju prvog mjesečnog plana $KPMP_1''$ zbog uzimanja u realizaciju sljedećeg tjednog dio drugog polaznog mjesečnog plana, čime se osigurava kontinuitet realizacije i upravljanja proizvodnjom.

Korekcija prvog višeg plana određivati će se dinamiziranim programiranjem i u okviru njega će se odrediti njegova tri dijela-etape kao osnovni planovi za sljedeća tri kalendarska mjeseca, kao dijelovi optimalnog rješenja za sljedeće tromjesečje. Na isti način će se dinamiziranim programiranjem optimirati sljedeći viši plan.

No, moguće je da će se u slučaju većeg broja većih promjena i korekcija prvog višeg plana morati optimizirati putem oponašanja ako se ocijeni da bi se dinamiziranim programiranjem zbog prisutnih značajnih promjena bitno narušio plan realizacije već definiranih narudžbi, odnosno radnih naloga. Primjenom diskretnog korektivnog dinamiziranog optimiranja omogućava se prilagodljivost planiranja i praćenja jer se svakoj grupi polaznih optimalnih rješenja OP_i u određenim vremenskim razmacima pridružuje realno mogući dio promjena P_{ij} pa na taj način dobivamo korigirano optimalno rješenje OP_k.

Dobiveni korigirani optimumi mogu biti manji ili veći od polaznih optimuma, ovisno o karakteru i aktualnosti skupa promjena Pij, ali se zato sa sigurnošću postiže veća prilagodljivost proizvodnog sustava prema promjenama u okruženju i njemu samom.

Navedeno vrijedi kako za slučaj kada se radi korekcija osnovnog plana putem oponašanja po kriteriju $\Phi=\Phi(EK_{max})$ gdje je EK=IPP–PT (47), tako i za slučaj korekcije višeg plana putem dinamičkog programiranja po kriteriju $\Phi=\Phi(UP_{max})$ pri čemu je UP=IK·PF (40).

Skraćeni blok-dijagram diskretnog korektivnog dinamiziranog optimiranja prikazan je po svojim fazama na slici 25.

Procesom planiranja i praćenja u kojem se koristi diskretno korektivno dinamizirano optimiranje, gdje se tretiraju dospjele, aktualne promjene, omogućava se sljedeće:

1. Reagiranje na promjene u kraćem roku, uz traženje najpovoljnijeg korigiranog rješenja, jer se korekcije višeg plana rade u razdoblju prvog nižeg plana, a ne nakon isteka razdoblja tretiranog plana
2. Korekcije planova se rade pravovremeno, na osnovu mogućnosti za uključenje aktualnih promjena, a ne na osnovu prethodne statistike i naknadnim korigiranjem
3. Omogućava se pravovremena realizacija sadržaja planova
4. Osigurava se bolja priprema proizvodnog sustava i ostalih procesa za naredno razdoblje (nabava materijala, dodatni kapaciteti, dodatni rad i dr.) te se s još većom pouzdanošću planiraju sljedeća viša planska razdoblja

Predloženi model diskretnog korektivnog dinamiziranog optimiranja moguće je koristiti kod raznih tipova i vrsti proizvodnje, uz odgovarajuće napomene, kako slijedi:

A. U slučaju serijske proizvodnje za zalihe, gdje je proizvodni ciklus kraći ili dulji, moguće je pravovremeno mijenjati gornja i donja ograničenja količina za optimiranje linearnim programiranjem i na taj način smanjiti odstupanja u odnosu na stvarnost, a korekcijama u tijeku realizacije osnovnog plana točnost planiranja će se još povećati.
B. Ako se radi o serijskoj proizvodnji kombinirano po narudžbama i za zalihe, za proizvodnju koja ima kraći ili dulji ciklus, dobiti će se još veća točnost polaznih operativnih planova, a korekcijama u tijeku realizacije osnovnog plana točnost planiranja će biti još veća i tu će biti najefikasnije korištenje predloženog modela.
C. U slučaju proizvodnje serija proizvoda po narudžbi preciznost planiranja ovisiti će najvećim dijelom o korekcijama putem oponašanja s time da je tu istovremeno važno da se korekcije rade sukladno redosljedu lansiranja serija obzirom na utvrđene rokove
D. Za slučaj primjene diskretnog korektivnog dinamiziranog optimiranja u pojedinačnoj proizvodnji po narudžbi uspješnost planiranja i korekcija planova bitno će ovisiti o istovremenom usklađivanju tehnoloških operacija s planiranim korekcijama planova.

S obzirom da se radi o modelu prilagodljivog planiranja i praćenja, uspješnost će bitno ovisiti ne samo o tipu i načinu proizvodnje već i o stupnju neizvjesnosti i promjena.

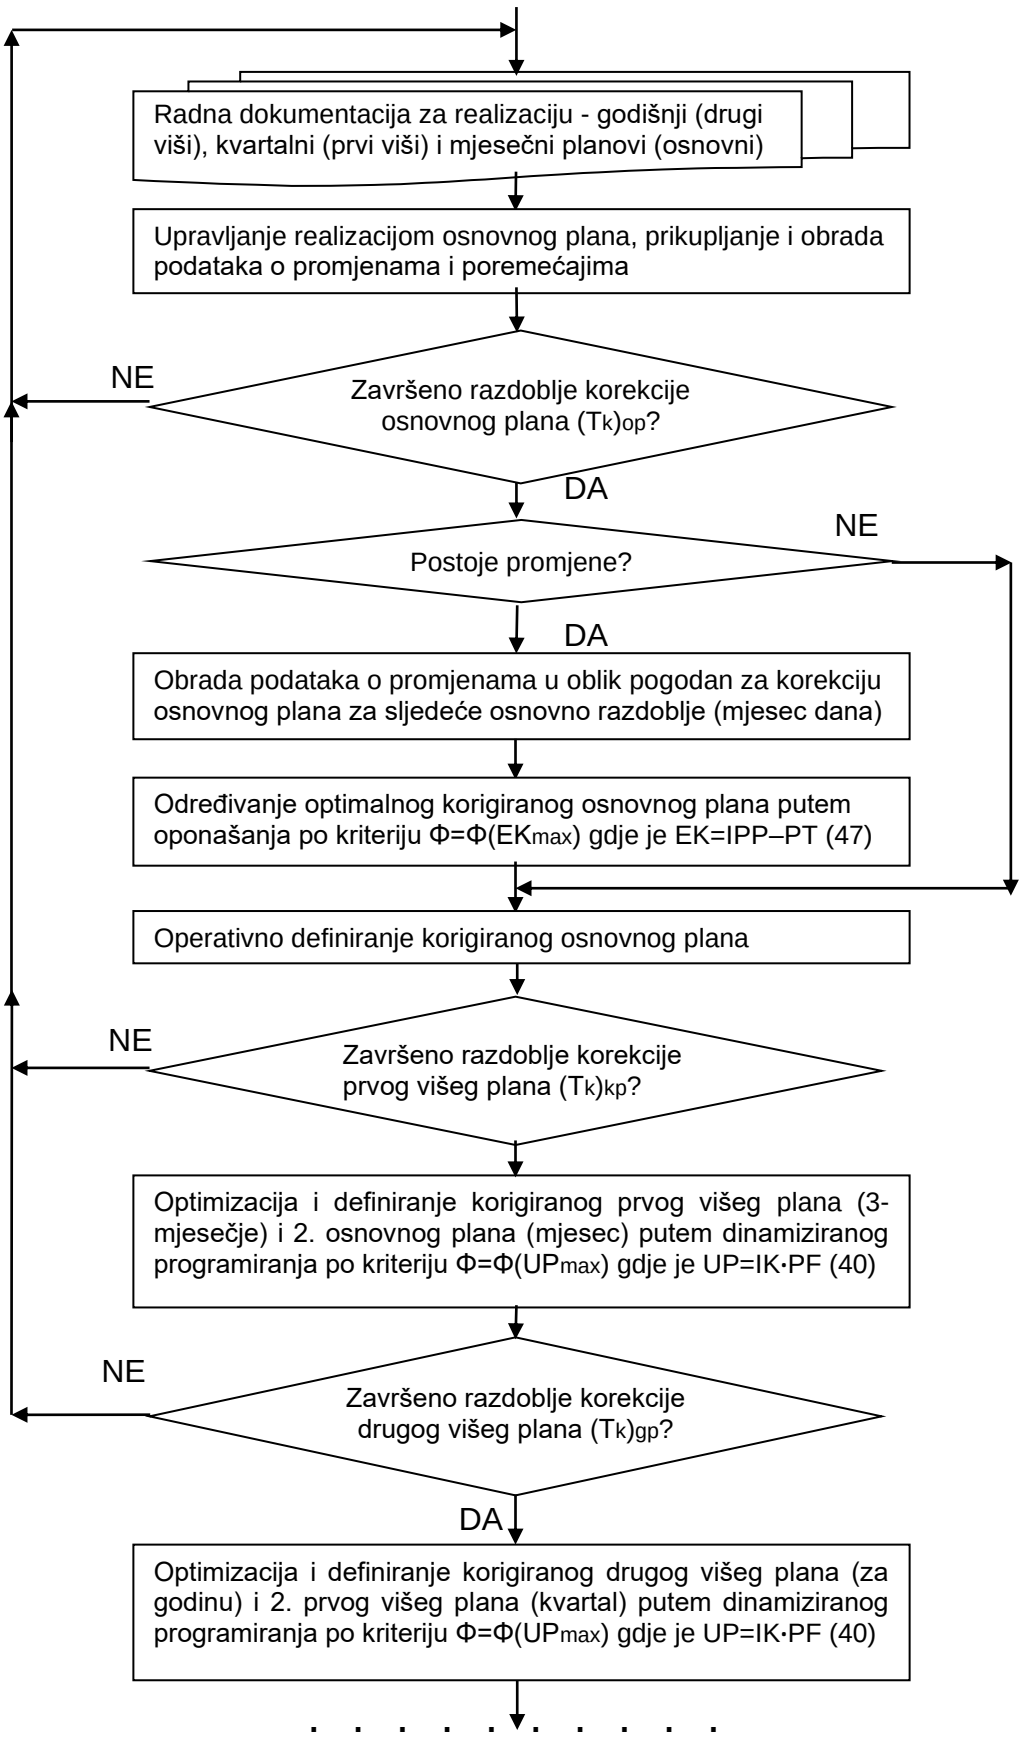

Slika 25. *Skraćeni blok-dijagram diskretnog korektivnog dinamiziranog optimiranja*

7. ZAVRŠNO RAZMATRANJE ISTRAŽIVANJA

7.1. Dokaz hipoteze

Postavljena **hipoteza** ovog istraživanja kaže da izbor modela i optimizacija procesa planiranja i praćenja proizvodnje značajno utječe na uspješnost i prilagodljivost proizvodnog sustava i poslovanja u uvjetima dinamičnih promjena u okruženju i samom proizvodnom sustavu, odnosno, da se modeliranjem i optimizacijom procesa planiranja i praćenja u smislu njegove prilagodljivosti može postići veći stupanj njegove uspješnosti i zadovoljenja potreba okruženja nego je to slučaj kod poznatih metoda i tehnika optimizacije planova proizvodnje.

Pri tome se mora naglasiti još jedna važna činjenica kod primjena matematičkih metoda i tehnika optimizacije, a to je da se stvarnost uvijek u većoj ili manjoj mjeri prilagođava matematičkom modelu. Zbog toga se događa slučaj, kako je to prikazano pomoću skupova na slici 26., da skup optimalne mogućnosti-rješenja S_o ne sadrži samo elemente iz skupa mogućnosti S_i već i dijelove izvan tog skupa, odnosno, imamo nesklad između optimalnih elemenata utvrđenih matematičkim programiranjem i realnih količina elemenata optimizacije.

Tako se u praksi često događa da npr. nekog proizvoda u optimalnom proizvodnom programu za neko razdoblje ima premalo, a nekog previše u odnosu na realnu potražnju. To dovodi do situacija da proizvodni sustav ili ne može isporučiti dio količina nekih proizvoda koje se realno traže na tržištu (loša reklama) ili ima viškova koji trenutno nisu traženi i tada se plasiraju uz lošije financijske uvjete. Ta odstupanja nisu u velikom postotku niti su velike vrijednosti, ali su dovoljna da poslovni sustav ima direktnu ili indirektnu štetu.

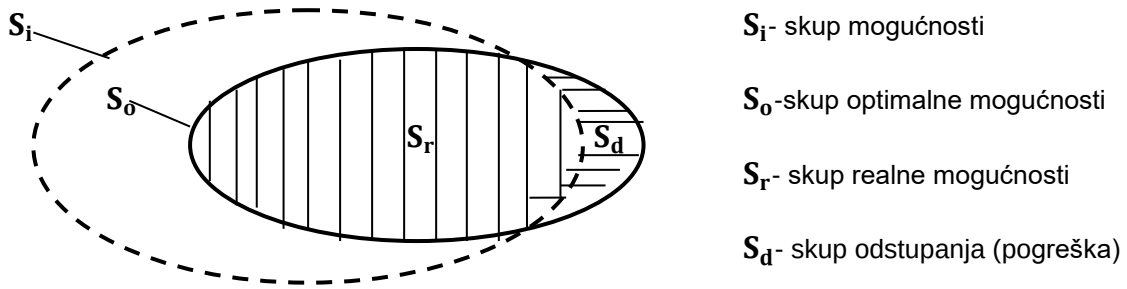

Slika 26. *Prikaz matematičke optimizacije pomoću skupova*

Možemo reći da je skup realne mogućnosti S_r presjek skupova S_i i S_o, kako je iskazano u izrazu (49), i da je skup odstupanja-pogreške S_d razlika između skupa optimalne mogućnosti S_o i skupa realne mogućnosti S_r, definirano u izrazu (50).

$$S_r = S_i \cap S_o = \{ x \in S_i | \, x \in S_i \; \& \; x \in S_o \} \tag{49}$$

$$S_d = S_o \setminus S_r = \{ x \in S_o | \, x \in S_o \; \& \; x \notin S_r \} \tag{50}$$

U slučaju primjene diskretnog korektivnog dinamiziranog optimiranja, čiji je tijek prikazan na slici 27., za odabrano plansko razdoblje t_j u obzir se uzimaju i promjene S_p koje se događaju u okruženju i sustavu za vrijeme tretiranog planskog razdoblja za svako vremensko razdoblje korekcije t_i. Iste se uzimaju u obzir prilikom optimizacije prilagođenog plana za plansko razdoblje, te se obavlja korekcija optimalnog plana S_{o_j} i njegova transformacija u prilagođeni plan $S^1_{o_j}$.

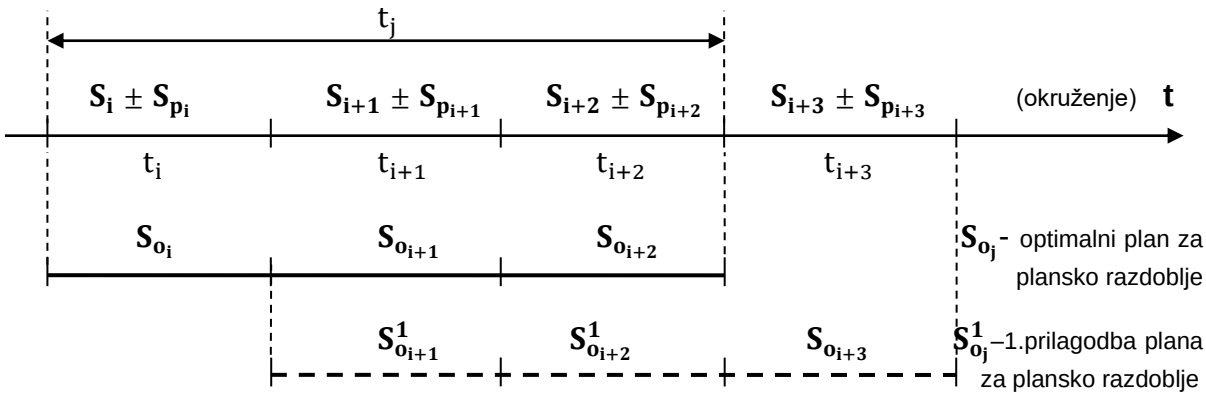

Slika 27. *Prikaz tijeka diskretnog korektivnog dinamiziranog optimiranja*

Pri tome između skupova i poskupova mogućnosti i rješenja imamo odnose navedene u izrazima (51), (52) i (53), kako slijedi:

$$S_{o_j} = S_{o_i} + S_{o_{i+1}} + S_{o_{i+2}} \tag{51}$$

$$S^1_{o_j} = S^1_{o_{i+1}} + S^1_{o_{i+2}} + S_{o_{i+3}} \tag{52}$$

$$S^1_{o_{i+1}} = S_{o_{i+1}} \pm S_{k_{i+1}}; \;\; S^1_{o_{i+2}} = S_{o_{i+2}} \pm S_{k_{i+2}} \tag{53}$$

To znači da će korigirani, prilagođeni optimalni plan $S^1_{o_j}$ za tretirano plansko razdoblje nakon isteka prvog razdoblja korekcije t_i biti prema izrazu (52) sastavljen od prethodno definiranih, a sada prilagođenih dijelova $S^1_{o_{i+1}}$ i $S^1_{o_{i+2}}$ te novog dijela $S_{o_{i+3}}$.

Prema izrazu (53) korigirani, prilagođeni dijelovi novog optimalnog plana $S^1_{o_{i+1}}$ i $S^1_{o_{i+2}}$ su skupovi koji sadrže dijelove iz prethodno optimiranih skupova $S_{o_{i+1}}$ i $S_{o_{i+2}}$ te dijelove iz skupova promjena $S_{p_{i+1}}$ i $S_{p_{i+2}}$ koji sada predstavljaju skupove korekcija $S_{k_{i+1}}$ i $S_{k_{i+2}}$.

Ako navedeni način rada prikažemo pomoću skupova na primjeru za dio optimalnog rješenja za plansko razdoblje, kako se to vidi na slici 28., možemo zaključiti da je korigirani dio optimalnog plana $S^1_{o_{i+1}}$ unija skupova većeg dijela prethodnog optimalnog plana $S_{o_{i+1}}$ i dijela skupa promjena $S_{p_{i+1}}$ koji se naziva skup korekcije plana $S_{k_{i+1}}$, iskazano u izrazu (56).

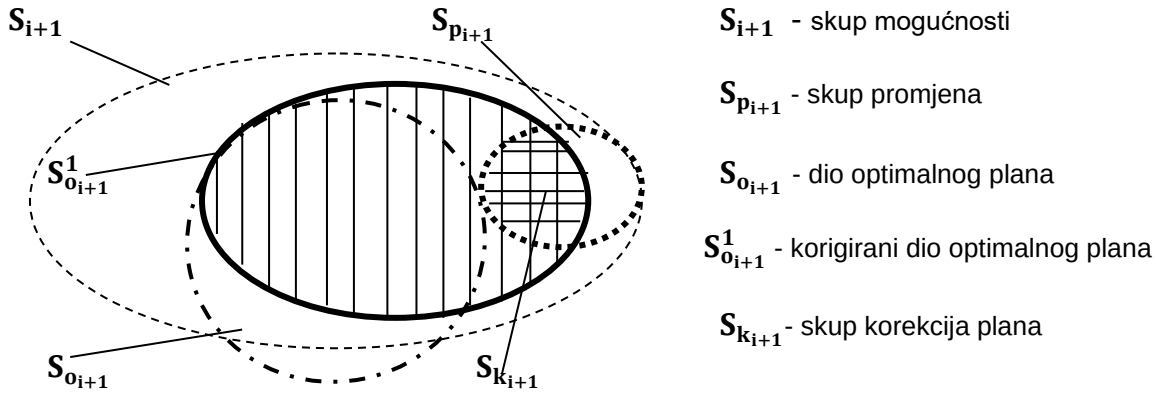

Slika 28. *Prikaz dokaza hipoteze pomoću skupova*

To znači da je svaki element ***x*** skupa korigiranog dijela optimalnog plana $S^1_{o_{i+1}}$ sadržan ili u skupu dijela prethodno optimiziranog plana $S_{o_{i+1}}$ ili u skupu korekcija plana $S_{k_{i+1}}$.

$$S^1_{o_{i+1}} = S_{o_{i+1}} \cup S_{k_{i+1}} = \{ x \in S^1_{o_{i+1}} \mid x \in S_{o_{i+1}} \vee x \in S_{k_{i+1}} \} \tag{54}$$

Prema izrazu (47) to znači da se za razliku skupova $S^1_{o_{i+1}}$ i $S_{o_{i+1}}$ može reći da je svaki element ***x*** skupa korigiranog dijela optimalnog plana $S^1_{o_{i+1}}$ sadržan u tom skupu i istovremeno nije sadržan u skupu $S_{o_{i+1}}$

$$S^1_{o_{i+1}} \setminus S_{o_{i+1}} = \{ x \in S^1_{o_{i+1}} \mid x \in S^1_{o_{i+1}} \& \, x \notin S_{o_{i+1}} \} \tag{55}$$

iz čega se zaključuje da tu razliku čine elementi skupa korekcije $S_{k_{i+1}}$, sukladno izrazu (56),

$$S^1_{o_{i+1}} \setminus S_{o_{i+1}} = \{ x \in S_{k_{i+1}} \} \tag{56}$$

Stoga se može reći da diskretno korektivno dinamizirano optimiranje kao izbor modela i optimizacija procesa planiranja i praćenja proizvodnje svakako utječe na uspješnost i prilagodljivost proizvodnog sustava i poslovanja u uvjetima dinamičnih promjena u okruženju i samom proizvodnom sustavu.

Prilagodljivost proizvodnog sustava u odnosu na promjene u samom sustavu i njegovom okruženju uvijek je djelomična, manje ili više, kako zbog brojnih ograničenja tako i zbog tromosti proizvodnog sustava.

No, sa sigurnošću se može tvrditi da će kod primjene diskretnog korektivnog dinamiziranog optimiranja planovi svih nivoa biti objektivniji i bliži realnosti nego kod bilo kojeg drugog modela optimiranja u procesu planiranja i praćenja proizvodnje.

Jasno je također da proizvodni sustav ne može reagirati na svaku promjenu, ali se iz navedenog može zaključiti da se primjenom diskretnog korektivnog dinamiziranog optimiranja sustav može više i pouzdanije prilagođavati dinamičnim promjenama nego što je to slučaj kod do sada poznatih modela i metoda optimizacije.

7.2. Ispitivanje modela korektivnog optimiranja

Najveći broj istraživanja planiranja i praćenja proizvodnje u zadnjih 10 godina bavi se istraživanjem tog područja u specifičnim slučajevima ili u slučajevima neizvjesnosti pri čemu se sve više naglašava nužnost značajnijeg heurističkog pristupa za što se predlažu sljedeći modeli rješenja planiranja i praćenja proizvodnje:

a. primjena heurističkih metoda pri kombiniranoj proizvodnji za zalihe i po narudžbi [12, 13]
b. model planiranja kapaciteta za duže vremensko razdoblje zbog veće fleksibilnosti proizvodnje i brže isporuke proizvoda [15]
c. model planiranja u uvjetima nestabilnosti s obvezom postizanja rokova [21]
d. oponašanje kao model optimiranja proizvodnje za slučajeve proizvodnje po narudžbi i u uvjetima nestabilnosti [22, 24, 25, 26, 30]
e. optimiranje u proizvodnji po narudžbi sa selekcioniranjem narudžbi sukladno rokovima i kapacitetima [32]
f. model optimiziranja planova proizvodnje uz primjenu metode oponašanja zbog uključivanja dodatnih narudžbi u planove te sinhronizacije prodaje i proizvodnje [35]

Također se može utvrditi da zapravo nema modela planiranja i praćenja proizvodnje koji se mogu poopćiti za veći broj uvjeta i različite vrste proizvodnje pa je i zbog toga vrlo teško precizno uspoređivati efikasnost aktualnih modela planiranja i praćenja proizvodnje.

Zbog toga je realno da će zbog sve veće prisutnosti neizvjesnosti i promjena u okruženju budući modeli imati još značajnije prisustvo heurističkog pristupa u njihovom oblikovanju, a to znači sve veći dio rješenja zasnovan na iskustvu. Tada se istovremeno postavlja pitanje određivanja egzaktnog optimuma pa je izvjesnije da će se stvarati modeli koji će u posebnim uvjetima davati približne optimume a da pri tome korištene metode daju rješenja koja će biti u što većoj mjeri prilagođena promjenama u okruženju i samom proizvodnom sustavu.

Iako je namjera razviti model koji će pronaći optimalno rješenje, to je ponekad preteško pa se treba zadovoljiti i nekim dopustivim rješenjem koje ne mora nužno biti optimalno, ali zadovoljava sve uvjete problema. Vrlo često metode približnog računanja imaju čvrstu matematičku pozadinu koja svjedoči o njihovoj pouzdanosti neovisno o ulaznim podacima. U isto vrijeme daju i ocjenu konvergencije pa se uvijek može znati koliko je blizu (ili daleko) optimalnom rješenju.

U prethodnom poglavlju je putem matematičko-logičkog postupka dokazana hipoteza ovog istraživanja da izbor modela i optimizacija procesa planiranja i praćenja proizvodnje značajno utječe na uspješnost i prilagodljivost proizvodnog sustava i poslovanja u uvjetima dinamičnih promjena u okruženju i samom proizvodnom sustavu. Ovdje će se na praktičnom primjeru ispitati model korektivnog optimiranja nazvan diskretno korektivno dinamizirano programiranje i na taj način još jednom potvrditi gore navedena hipoteza ovog istraživanja.

Za prvo ispitivanje su uzeti podaci iz praktičnog primjera koji je poslužio i u prethodnom dijelu ovog istraživanja, a gdje je obuhvaćeno 6 grupa proizvoda za razdoblje od prvih 6 karakterističnih mjeseci u godini. Za drugo ispitivanje je uzet primjer proizvodnje autostakla s 10 grupa proizvoda u razdoblju također prvih 6 mjeseci u godini. Ispitivanje je izvršeno na način da su se usporedili rezultati optimiranja planova proizvodnje sa stvarno ostvarenim rezultatima iz odabranog praktičnog primjera, a za usporedbu s tim rezultatima odabrani su sljedeći modeli optimiranja planova proizvodnje:

A - Linearno programiranje

B - Dinamizirano programiranje

C - Linearno programiranje s korektivnim optimiranjem putem oponašanja

D - Diskretno korektivno dinamizirano programiranje

Obzirom na raspoložive mogućnosti za ispitivanje, modeli B, C i D ponešto su pojednostavljeni i to na način da im je svima osnova bila simplex metoda linearnog programiranja za što je na rapolaganju bio potrebni software. Promjenom dijela parametara simplex metoda je prilagođena ostalim navedenim modelima na odgovarajući način, a kod modela C i D dodana je pojednostavljena tehnika oponašanja.

Kod primjene linearnog programiranja simplex metodom, kao model A, za gornju i donju granicu potražnje proizvoda uzeti su podaci o rasipanju realizacije na tržištu pa je kao gornja granica za svaki tretirani mjesec uzeta najveća ostvarena realizacija svakog proizvoda, a kao donja granica je uzeta najniža ostvarena realizacija tog proizvoda u mjesecu.

Pojednostavljeni model dinamiziranog programiranja, kao model B, napravljen je tako da se dio dodatnih narudžbi, kao iskaz promjena u okolini, uključio u određivanje gornje i donje granice potražnje proizvoda u svakom mjesecu. Time je obuhvaćen dio narudžbi koje se zaprimaju u tekućem mjesecu za prvi dio tekućeg mjeseca, a iz tretiranja su isključene dodatne narudžbe koje su tražene za isporuku u drugom dijelu tekućeg mjeseca. Generiranjem dijela dodatnih narudžbi izvršena je korekcija gornje i donje granice potražnje proizvoda za približno 25-50% od ukupnog učešća dodatnih narudžbi svakog proizvoda u svakom mjesecu nakon čega je primjenjeno linearno programiranje simplex metodom u tim novim uvjetima.

Kao treći, C model za ispitivanje, uzet je model linearnog programiranja s korektivnim optimiranjem putem oponašanja gdje se polazni optimalni plan mijenja na osnovu promjena – izvanrednih, tj. neočekivanih dodatnih narudžbi tijekom tekućeg mjeseca uz korištenje metode oponašanja. Kod ovog modela polazni plan predstavlja rješenje po prvo navedenom A modelu linearnog programiranja korištenjem simplex metode, a korekcije aktualnog plana su rađene za sve neočekivane dodatne narudžbe koje se trebaju realizirati u razdoblju aktualnog operativnog plana.

Diskretno korektivno dinamizirano programiranje, kao model D, također je nešto pojednostavljeno za ovo ispitivanje na način da je dio dodatnih narudžbi uvrštavan u aktualni operativni plan temeljem primjene kliznog planiranja (periodičkim ponavljanjem), a drugi dio, približno kao i ukupno učešće dodatnih narudžbi svakog proizvoda u svakom mjesecu, tj. neočekivane dodatne narudžbe, bio je osnova za korekciju tekućeg plana primjenom metode oponašanja. U suštini je to bila kombinacija dinamiziranog programiranja (model B za testiranje) i korektivnog optimiranja primjenom metode oponašanja.

Kod sva 4 modela koja su ispitivana i čiji su rezultati uspoređivani sa ostvarenim rezultatima iz praktičnog primjera korištenog u ovom istraživanju kriterij optimizacije je bila uspješnost proizvodnje-poslovanja UP prema izrazu (40) iz poglavlja 6.5.

$$UP = IK \cdot PF \tag{40}$$

gdje je: IK – iskoristivost kapaciteta (mjereno u decimalnom iskazu postotka)

PF – profitna stopa (mjereno u decimalnom iskazu postotka)

Za ispitivanje odabranih modela u odnosu na rezultate iz praktičnog primjera korišten je kriterij prilagodljivosti PG prema izrazu (57)

$$PG = \Sigma \Delta Q_i / p \tag{57}$$

gdje je: $\Sigma \Delta Q_i$ – razlika planiranih i realiziranih količina u decimalno iskazanom postotku

p – broj tretiranih grupa proizvoda

pri čemu je funkcija prilagodljivosti $\Phi = \Phi\ (PG_{min})$.

Korekcija operativnih planova kod ispitivanih modela C i D nije optimizirana prema kriteriju maksimizacije po izrazu (47) već je napravljena prema mogućim, najpovoljnijim rješenjima uz korištenje kriterija najmanjeg gubitka profitne stope GP prema izrazu (58)

$$GP = (1 - \Delta PF) \tag{58}$$

Naime, zbog uspoređivanja ispitivanih modela optimizacije sa stvarnim rezultatima iz praktičnog primjera obzirom na kriterij prilagodljivosti, raspoloživi kapacitet je bio konstanta. Istovremeno je korišten kriterij zadržavanja iste profitne stope, a glavni je cilj bilo postizanje veće prilagodljivost planova u odnosu na promjene iz zahtjeve iz okoline-tržišta.

Korekcije proizvoda u planovima rađene su prema pokazateljima isplativosti KS_i (59) i korekcije Kp_{ij} (60)

$$KS_i = ZK_i \cdot PS_i, \tag{59}$$

$$Kp_{ij} = ZK_{ij} / PS_{ij} \tag{60}$$

gdje je: ZK – učešće u zauzimanju kapaciteta

PS – profitna stopa

na način da su dopunske narudžbe uvrštavane u plan na račun proizvoda iz plana za koje nema dopunskih narudžbi, po kriteriju $(KS_i)_{max}$ i $(Kp_{ij})_{max}$.

Ispitivanje navedena 4 modela optimizacije izvršeno je na dva praktična primjera iz proizvodnje posuđa (Gorica d.d.) i proizvodnje autostakla (Lipik Glas d.d.)

U odabranim primjerima korištenim u ovom ispitivanju ostvarena je prosječna realizacija na tržištu Q_{1j} u gornjim Q_{ij}^{g} i donjim granicama Q_{ij}^{d}, kako je to prikazano u prilogu 9.2.

Blok-dijagram ispitivanja različitih modela optimizacije prikazan je na slici 29., a za izradu software-a korišten je sustav MATLAB. Software identičan za oba praktična primjera testiranja prikazan je u prilogu 9.2.-1, dok se primjeri originalno dobivenih rezultata za proizvodnju autostakla nalaze u prilogu 9.2.-2.

U prikazu polaznih podataka o dopunskim narudžbama te dobivenih rezultata po svakom modelu optimiranja, u stupcima su proizvodi po grupama od P1 do P6 u prvom primjeru, odnosno od A1 do A10 u drugom primjeru, a redovi predstavljaju prvih 6 mjeseci u godini.

Kako je navedeno u opisanim primjerima, pojavljuju se očekivane dodatne narudžbe Qd_{ij} za tekuće operativno plansko razdoblje, koje je bilo za jedan mjesec, u prosječnim veličinama. Također se s određenom vjerojatnošću pojavljuju i izvanredne, neočekivane dodatne narudžbe Qv_{ij} u tekućem operativnom razdoblju s rokovima isporuke u tom istom razdoblju i prosječnim veličinama.

Za ispitivanje i usporedbu odabranih modela programiranja optimalne proizvodnje još su korišteni podaci o proizvodnji odabranih praktičnih primjera, a koji su bili potrebni za primjenu metoda optimizacije i koji su prikazani u tablici 23., dok su u tablici 24. navedena ograničenja kapaciteta po mjesecima zbog uspoređivanja odabranih metoda optimizacije.

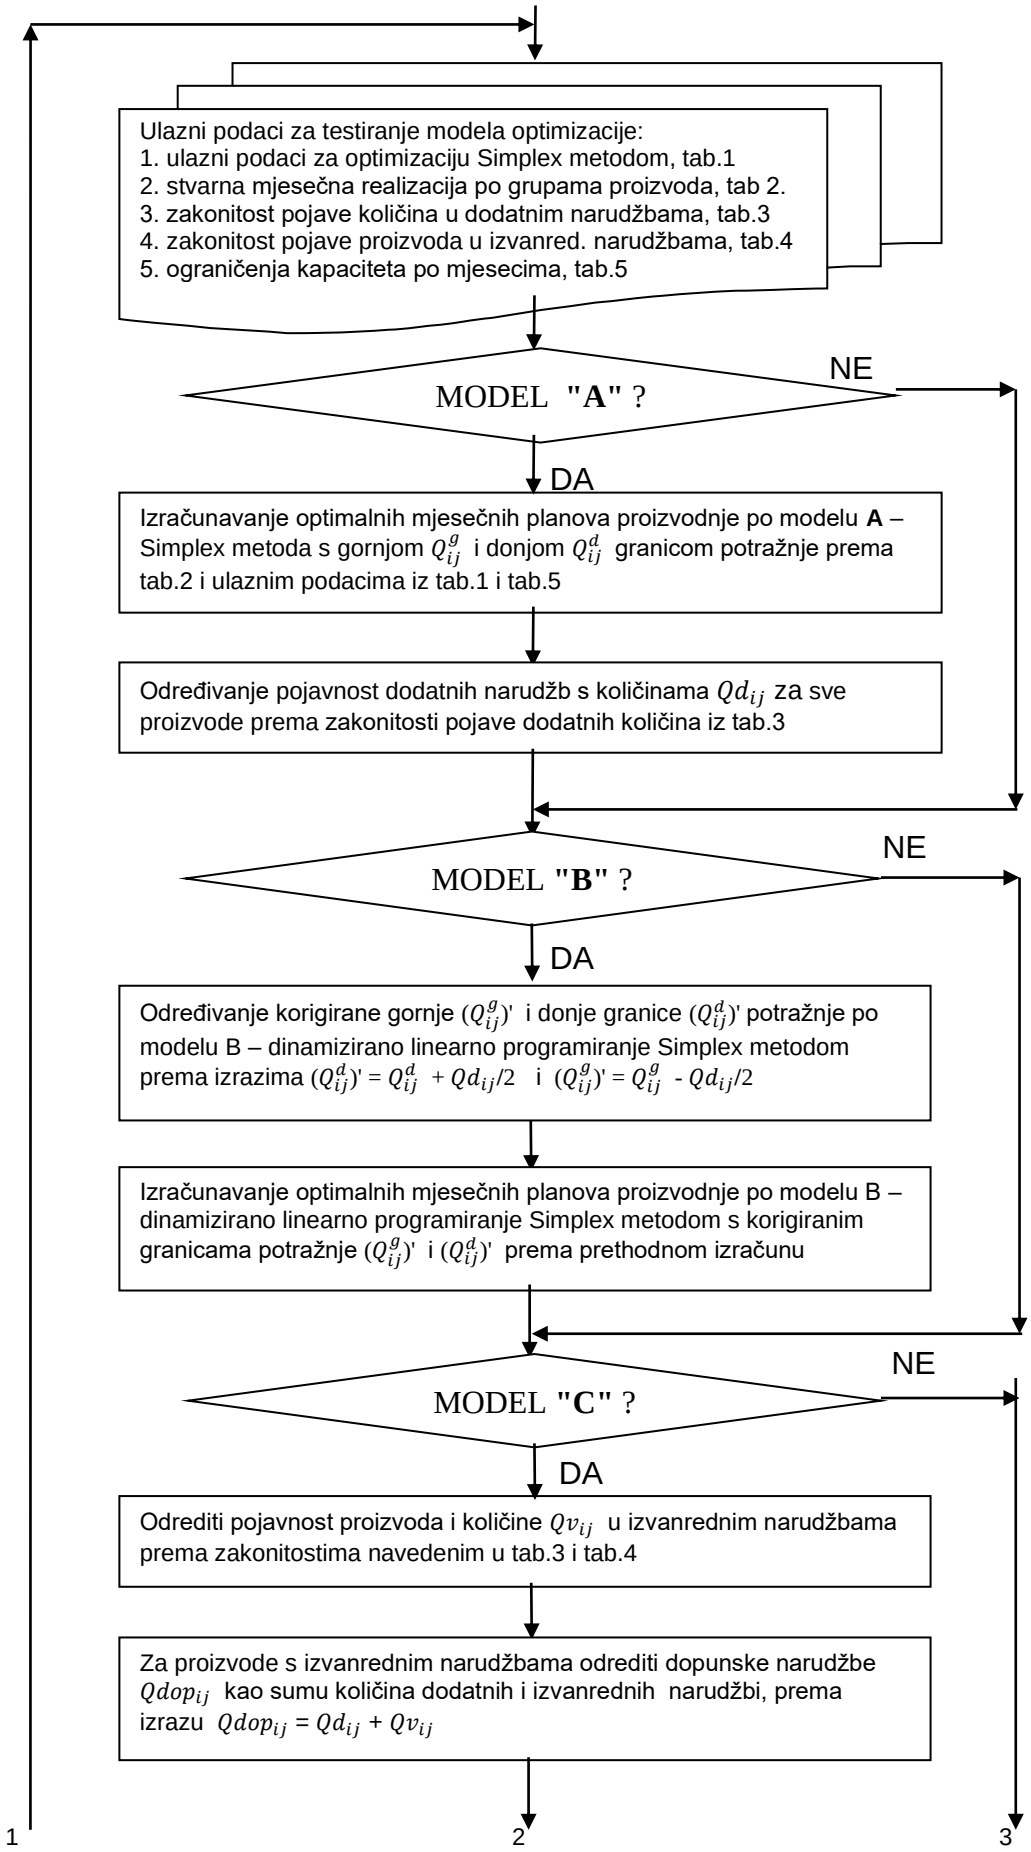
Ulazni podaci za testiranje modela optimizacije:
1. ulazni podaci za optimizaciju Simplex metodom, tab.1
2. stvarna mjesečna realizacija po grupama proizvoda, tab 2.
3. zakonitost pojave količina u dodatnim narudžbama, tab.3
4. zakonitost pojave proizvoda u izvanred. narudžbama, tab.4
5. ograničenja kapaciteta po mjesecima, tab.5
MODEL "A" ?
NE
DA
Izračunavanje optimalnih mjesečnih planova proizvodnje po modelu A – Simplex metoda s gornjom Q_{ij}^{g} i donjom Q_{ij}^{d} granicom potražnje prema tab.2 i ulaznim podacima iz tab.1 i tab.5
Određivanje pojavnost dodatnih narudžb s količinama Qd_{ij} za sve proizvode prema zakonitosti pojave dodatnih količina iz tab.3
MODEL "B" ?
NE
DA
Određivanje korigirane gornje $(Q_{ij}^{g})'$ i donje granice $(Q_{ij}^{d})'$ potražnje po modelu B – dinamizirano linearno programiranje Simplex metodom prema izrazima $(Q_{ij}^{d})' = Q_{ij}^{d} + Qd_{ij}/2$ i $(Q_{ij}^{g})' = Q_{ij}^{g} - Qd_{ij}/2$
Izračunavanje optimalnih mjesečnih planova proizvodnje po modelu B – dinamizirano linearno programiranje Simplex metodom s korigiranim granicama potražnje $(Q_{ij}^{g})'$ i $(Q_{ij}^{d})'$ prema prethodnom izračunu
MODEL "C" ?
NE
DA
Odrediti pojavnost proizvoda i količine Qv_{ij} u izvanrednim narudžbama prema zakonitostima navedenim u tab.3 i tab.4
Za proizvode s izvanrednim narudžbama odrediti dopunske narudžbe $Qdop_{ij}$ kao sumu količina dodatnih i izvanrednih narudžbi, prema izrazu $Qdop_{ij} = Qd_{ij} + Qv_{ij}$
1
2
3

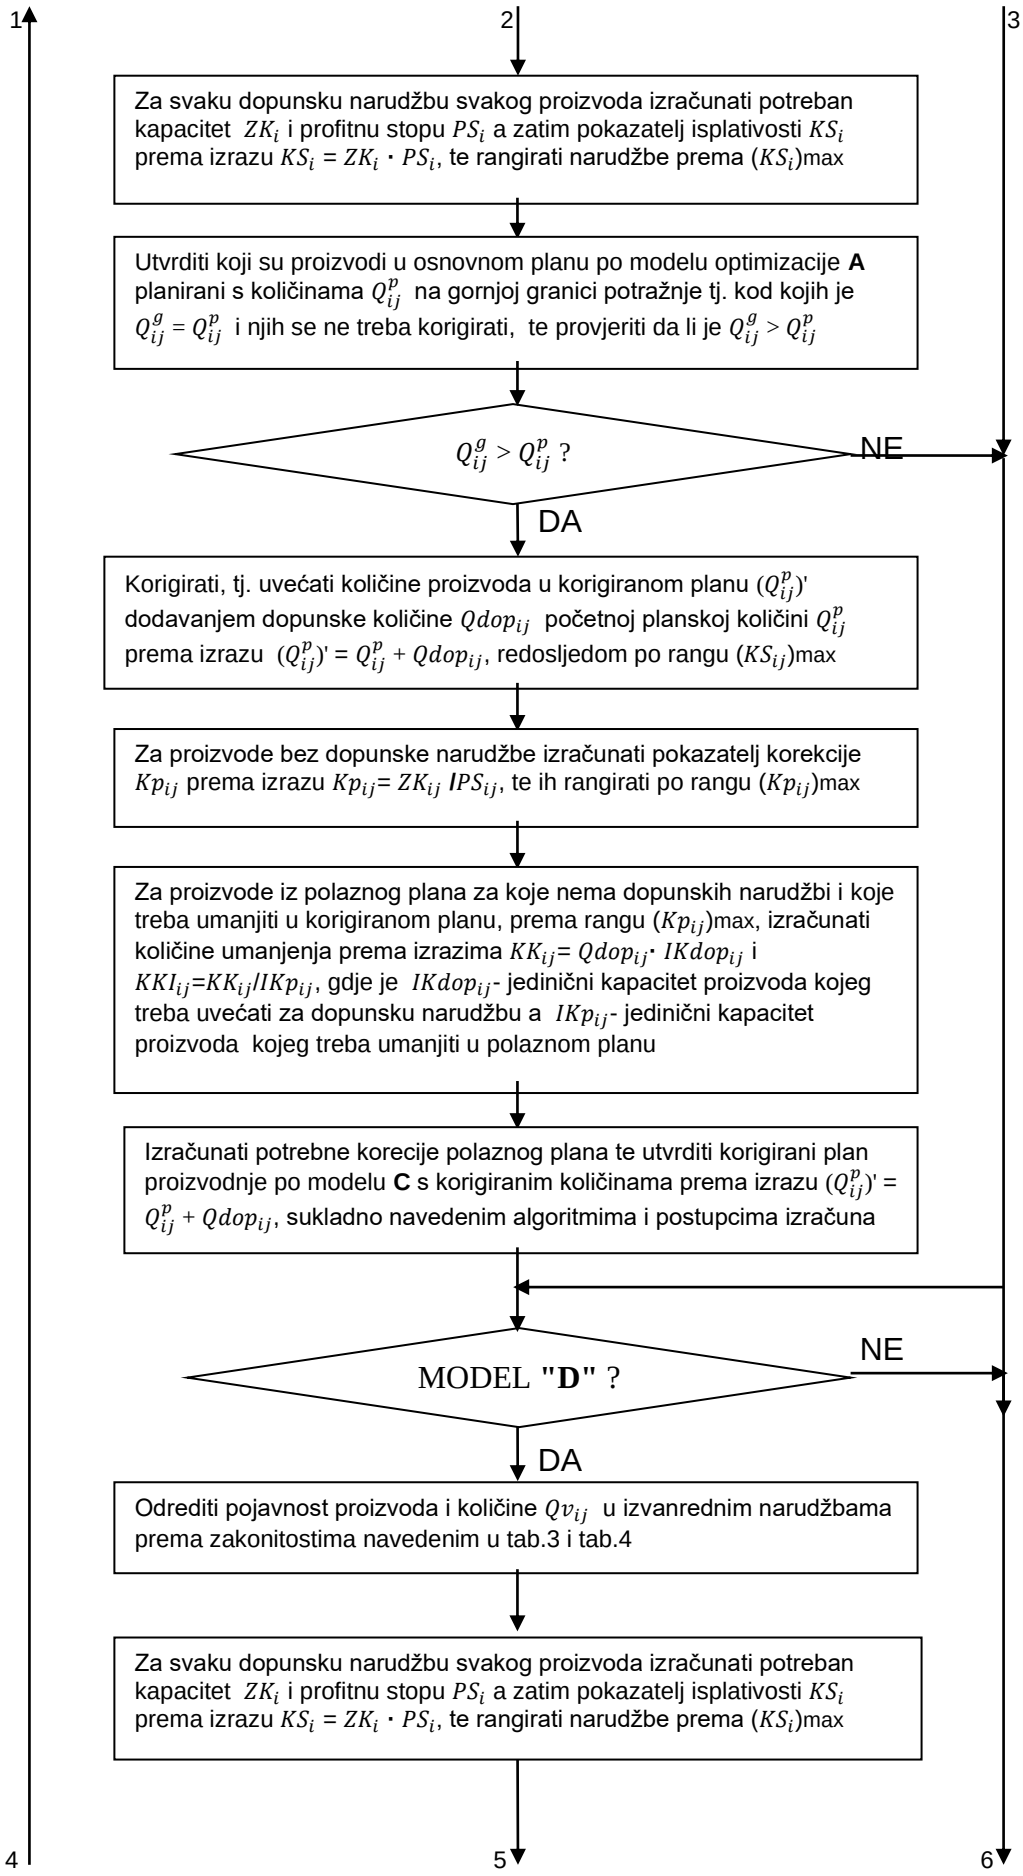
1
2
3
Za svaku dopunsku narudžbu svakog proizvoda izračunati potreban kapacitet ZK_i i profitnu stopu PS_i a zatim pokazatelj isplativosti KS_i prema izrazu $KS_i = ZK_i \cdot PS_i$, te rangirati narudžbe prema (KS_i)max
Utvrditi koji su proizvodi u osnovnom planu po modelu optimizacije **A** planirani s količinama Q_{ij}^p na gornjoj granici potražnje tj. kod kojih je $Q_{ij}^g = Q_{ij}^p$ i njih se ne treba korigirati, te provjeriti da li je $Q_{ij}^g > Q_{ij}^p$
$Q_{ij}^g > Q_{ij}^p$?
NE
DA
Korigirati, tj. uvećati količine proizvoda u korigiranom planu $(Q_{ij}^p)'$ dodavanjem dopunske količine $Qdop_{ij}$ početnoj planskoj količini Q_{ij}^p prema izrazu $(Q_{ij}^p)' = Q_{ij}^p + Qdop_{ij}$, redosljedom po rangu (KS_{ij})max
Za proizvode bez dopunske narudžbe izračunati pokazatelj korekcije Kp_{ij} prema izrazu $Kp_{ij} = ZK_{ij} / PS_{ij}$, te ih rangirati po rangu (Kp_{ij})max
Za proizvode iz polaznog plana za koje nema dopunskih narudžbi i koje treba umanjiti u korigiranom planu, prema rangu (Kp_{ij})max, izračunati količine umanjenja prema izrazima $KK_{ij} = Qdop_{ij} \cdot IKdop_{ij}$ i $KKI_{ij} = KK_{ij} / IKp_{ij}$, gdje je $IKdop_{ij}$- jedinični kapacitet proizvoda kojeg treba uvećati za dopunsku narudžbu a IKp_{ij}- jedinični kapacitet proizvoda kojeg treba umanjiti u polaznom planu
Izračunati potrebne korecije polaznog plana te utvrditi korigirani plan proizvodnje po modelu **C** s korigiranim količinama prema izrazu $(Q_{ij}^p)' = Q_{ij}^p + Qdop_{ij}$, sukladno navedenim algoritmima i postupcima izračuna
MODEL "**D**" ?
NE
DA
Odrediti pojavnost proizvoda i količine Qv_{ij} u izvanrednim narudžbama prema zakonitostima navedenim u tab.3 i tab.4
Za svaku dopunsku narudžbu svakog proizvoda izračunati potreban kapacitet ZK_i i profitnu stopu PS_i a zatim pokazatelj isplativosti KS_i prema izrazu $KS_i = ZK_i \cdot PS_i$, te rangirati narudžbe prema (KS_i)max
4
5
6

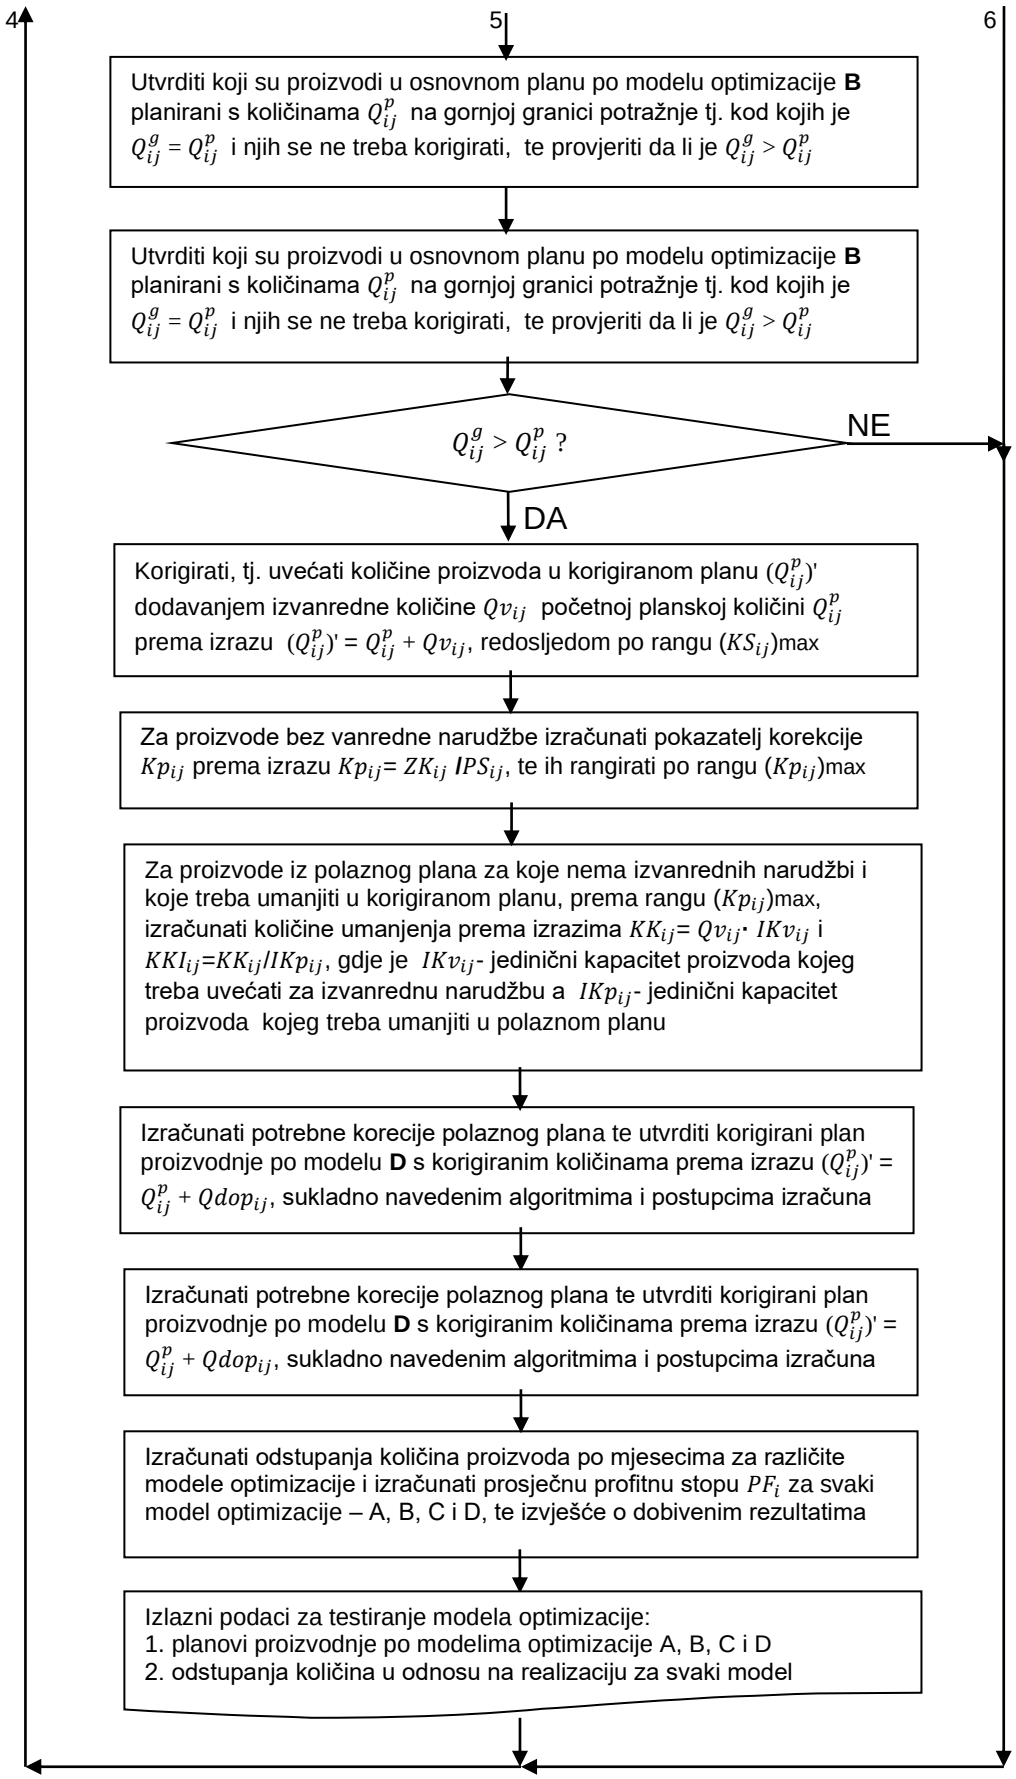

Slika 29. *Blok-dijagram ispitivanja različitih modela optimizacije*

Tablica 23. *Obilježja proizvodnje iz korištenih praktičnih primjera*

Obilježja	Pokazatelji po proizvodima									
I. Proizvodnja posuđa	P1	P2	P3	P4	P5	P6				
1. udio u kapacitetu 10000 kom.	0,08	0,06	0,03	0,03	0,04	0,05				
2. profitna stopa **PF_i**	0,14	0,18	0,10	0,11	0,12	0,08				
II. Proizvodnja autostakla	A1	A2	A3	A4	A5	A6	A7	A8	A9	A10
1. udio u kapacitetu 100 kom.	0,028	0,03	0,035	0,028	0,024	0,03	0,027	0,024	0,02	0,023
2. profitna stopa **PF_i**	0,11	0,12	0,10	0,09	0,08	0,10	0,09	0,07	0,07	0,08

Tablica 24. *Ograničenje kapaciteta proizvodnje po mjesecima*

	M J E S E C I					
Ograničenje kapaciteta po mjesecima	I.	II.	III.	IV.	V.	VI.
1. Proizvodnja posuđa, **IK_p**	0,75	0,86	0,92	0,80	0,70	0,61
2. Proizvodnja autostakla, **IK_a**	0,48	0,51	0,53	0,57	0,54	0,50

Parametri prilagodbe simplex metode za korištenje u osnovnom modelu i u ostalim modelima koji su uspoređivani simbolično su prikazani u grafičkom obliku na slici 30.

Izrada planova s korištenjem simplex metode linearnog programiranja (A) izvršena je na način da se kao ograničenje količina proizvoda za izradu operativnog plana OP_i koristio raspon realizacije na tržištu u zadnjih 5 godina s donjim Q_{ij}^d i gornjim Q_{ij}^g rasponom realizacije, a ograničenja kapaciteta IK_i po mjesecima bila su u veličinama iz tablice 24. Taj se postupak ponavlja u svakom tekućem razdoblju operativnog plana $R_i$za sljedeće razdoblje R_{i+1}.

Dinamizirano linearno programiranje (model B) je zapravo model linearnog programiranja koji je dijelom dinamiziran na način da se kliznim planiranjem i praćenjem u korigirane operativne planove uključuju dodatne narudžbe kupaca Qd_{ij} iz prethodnog razdoblja korekcije operativnog plana $(T_k)_o$, a koje onda smanjuju donje i gornje ograničenje potražnje u optimiranju po simplex metodi pa je tada ispravljeno donje $(Q_{ij}^d)'$ i gornje $(Q_{ij}^g)'$ ograničenje izračunato po sljedećim izrazima

$$(Q_{ij}^d)' = Q_{ij}^d + Qd_{ij}/2 \tag{61}$$

$$(Q_{ij}^g)' = Q_{ij}^g - Qd_{ij}/2 \tag{62}$$

Pri tome su u dodatne narudžbe kupaca Qd_{ij} uključene sve dodatne narudžbe iz prethodnih operativnih planskih razdoblja (R_{i-1}, R_{i-2}, ...), a koje treba izraditi i isporučiti u razdoblju R_i. Za te narudžbe postoje svi potrebni resursi ili ih je moguće odmah osigurati.

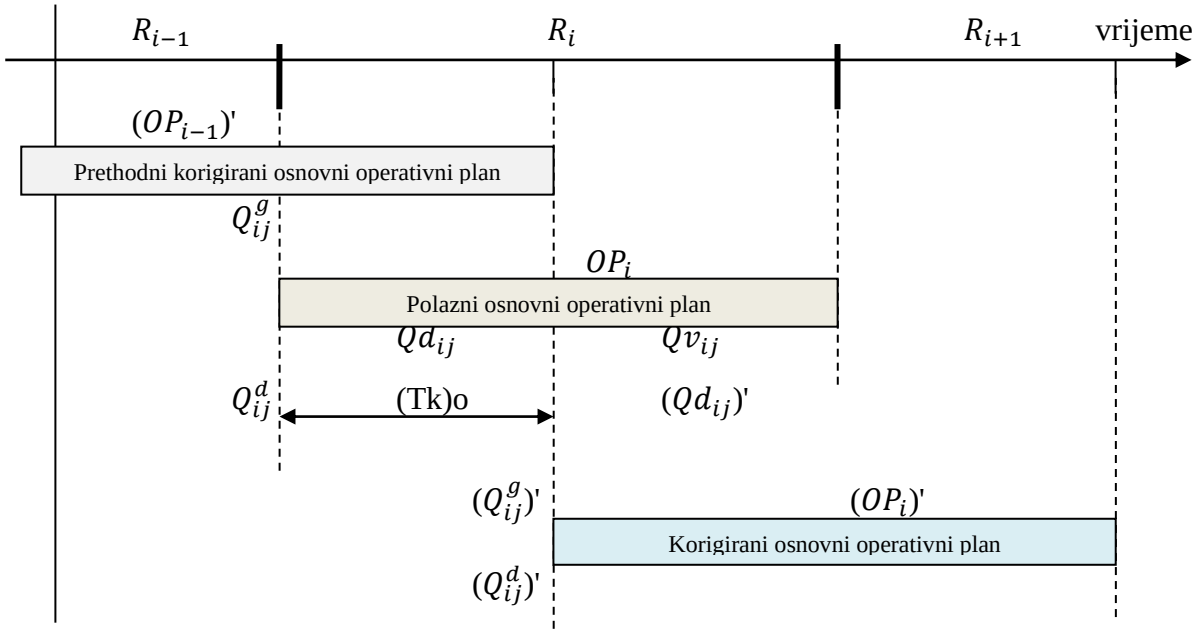

Slika 30. *Shematski prikaz podloga i postupka za modele optimizacije za ispitivanje*

Prema prikazu matematičke optimizacije pomoću skupova na slici 26. na stranici 152., uključivanjem podataka o promjenama potražnje na temelju dodatnih narudžbi smanjuje se dio skupa mogućnosti S_i a povećava se skup realnih mogućnosti S_r pa se samim tim smanjuje skup odstupanja-greške S_d, kao i skup korekcije S_k jer se smanjuje neizvjesnost.

Optimiranje planova proizvodnje po linearnom programiranju uz korekciju oponašanjem (C) izvedeno je na način da su se rješenja optimizacije po modelu A kao polazna rješenja korigirala oponašanjem sa dopunskim količinama $(Qd_{ij})'$ kao zbrojem količine neočekivanih dodatnih narudžbi proizvoda Qv_{ij} i njihovih očekivanih dodatnih količina Qd_{ij}.

Neočekivane dodatne narudžbe Qv_{ij} za koje su na raspolaganju potrebni resursi realizirati će se u drugom dijelu operativnog planskog razdoblja R_i, a ostale će postati dodatne narudžbe Qd_{ij} kod sljedeće korekcije operativnog plana. Za njih još trebao osigurati potrebne resursa u razdoblju R_{i+1} sljedećeg operativnog plana OP_{i+1}.

To znači da su korekcije odabranih proizvoda putem oponašanja rađene za ukupne količine $(Qd_{ij})'= Qd_{ij}+ Qv_{ij}$, po postupku prikazanom blok-dijagramom na slici 29.

U planovima proizvodnje dobiveni linearnim programiranjem i uz korekciju oponašanjem (model C) nisu korigirani proizvodi za koje su bile dopunske narudžbe jer su količine iz početnog plana bile na gornjoj granici potražnje.

Optimiranje planova proizvodnje uz primjenu pojednostavljenog diskretnog korektivnog dinamiziranog programiranja (model D) izvršeno je na način da su se rješenja optimizacije po modelu B kao polazna rješenja korigirala oponašanjem s količinama neočekivanih dodatnih narudžbi. To znači da su korekcije odabranih proizvoda rađene samo za količine Qv_{ij} , po postupku kao što je to bilo kod modela C, prema prikazu putem blok-dijagrama na slici 29.

U planovima proizvodnje dobivenim dinamiziranim linearnim programiranjem (model B) i uz korekciju oponašanjem (model D) također nisu korigirani proizvodi za koje su bile dopunske narudžbe jer su količine iz početnog plana bile na gornjoj granici potražnje.

Zbog veće vjerodostojnosti ispitivanja modela i vrednovanja efikasnosti modela diskretnog korektivnog dinamiziranog programiranja za oba praktična primjera ispitano je više varijanti slučajeva u okruženju variranjem veličina sljedećih parametara:

a. X - stupanj neizvjesnosti-rizika u okruženju
b. Y – učešće očekivanih dodatnih narudžbi
c. Z – učešće izvanrednih, neočekivanih dodatnih narudžbi

Stupanj neizvjesnosti kao oblik rizika predstavlja vjerojatnost odstupanja od uobičajnih, vremenom utvrđenih minimalnih i maksimalnih granica potražnje proizvoda, odnosno razlike gornje Q_{ij}^{g} i donje Q_{ij}^{d} granice potražnje. Ta će razlika biti veća ako se povećava postotak proizvodnje po narudžbi, odnosno ako rastu dodatne Qd_{ij} i izvanredne Qv_{ij} narudžbe.

Prilikom ispitivanja modela optimizacije varijabla X_i kao stupanj neizvjesnosti-rizika poprimala je veličine proporcionalne učešću očekivanih i neočekivanih dodatnih narudžbi, u rasponu 0-8%, a što je prikazano odgovarajućim indeksom uz varijablu X.

Kombinacije-varijante slučajeva za testiranje dobivale su se kombiniranjem polaznih i multipliciranih veličina očekivanih Qd_{ij} i neočekivanih Qv_{ij} dodatnih narudžbi gdje je $Y_1=Qd_{i1}$, $Y_2=2Qd_{i1}$, $Y_3=3Qd_{i1}$, $Y_4=4Qd_{i1}$, a isto tako je $Z_1=Qv_{i1}$, $Z_2=2Qv_{i1}$, $Z_3=3Qv_{i1}$, $Z_4=4Qv_{i1}$ pa je dobiveno 10 varijanti-slučajeva koji su ispitivani za svaki model optimizacije.

U tablici 25. su prikazani rezultati na primjeru proizvodnje posuđa, a u tablici 26. su rezultati dobiveni na primjeru proizvodnje autostakla koji su još i grafički prikazani na slikama 31., 32., 33. i 34.

Tablica 25. *Rezultati ispitivanja modela optimizacije na primjeru proizvodnje posuđa*

	Odstupanje količina ΔQ_i / Profitna stopa PF_i (%)			
Varijante testiranja	Model **A**	Model **B**	Model **C**	Model **D**
01. **Varijanta $X_0Y_1Z_1$**	**7,69** /11,48	**4,82** /11,45	**6,86** /11,42	**4,32** /11,42
02. **Varijanta $X_2Y_2Z_1$**	**9,37** /11,50	**4,40** /11,44	**8,57** /11,43	**3,95** /11,42
03. **Varijanta $X_3Y_1Z_2$**	**10,18** /11,51	**6,97** /11,48	**8,54** /11,45	**6,21** /11,45
04. **Varijanta $X_4Y_2Z_2$**	**11,00** /11,51	**4,58** /11,44	**9,50** /11,40	**4,24** /11,41
05. **Varijanta $X_4Y_3Z_1$**	**11,00** /11,51	**5,62** /11,46	**9,46** /11,41	**4,77** /11,43
06. **Varijanta $X_4Y_1Z_3$**	**11,00** /11,51	**8,20** /11,49	**9,16** /11,39	**7,34** /11,40
07. **Varijanta $X_5Y_3Z_3$**	**11,81** /11,52	**6,56** /11,47	**10,21** /11,40	**5,94** /11,41
08. **Varijanta $X_5Y_4Z_2$**	**11,81** /11,52	**6,21** /11,46	**11,19** /11,42	**5,94** /11,41
09. **Varijanta $X_6Y_2Z_4$**	**12,63** /11,53	**9,43** /11,49	**11,83** /11,41	**8,69** /11,42
10. **Varijanta $X_8Y_4Z_4$**	**14,25** /11,54	**7,97** /11,48	**12,84** /11,41	**7,46** /11,41

Tablica 26. *Rezultati ispitivanja modela optimizacije na primjeru proizvodnje autostakla*

	Odstupanje količina / Profitna stopa (%)			
Varijante testiranja	Model **A**	Model **B**	Model **C**	Model **D**
01. **Varijanta $X_0Y_1Z_1$**	**6,18** / 8,86	**3,83** / 8,82	**5,37** / 8,77	**3,21** / 8,77
02. **Varijanta $X_2Y_2Z_1$**	**7,42** / 8,88	**2,84** / 8,79	**6,84** / 8,78	**2,56** / 8,77
03. **Varijanta $X_3Y_1Z_2$**	**7,99** / 8,89	**5,01** / 8,84	**6,83** / 8,76	**4,53** / 8,76
04. **Varijanta $X_4Y_2Z_2$**	**8,54** / 8,90	**2,91** / 8,80	**7,09** / 8,78	**2,71** / 8,77
05. **Varijanta $X_4Y_3Z_1$**	**8,54** / 8,90	**3,91** / 8,82	**6,96** / 8,77	**3,40** / 8,78
06. **Varijanta $X_4Y_1Z_3$**	**8,54** / 8,90	**6,27** / 8,86	**6,92** / 8,75	**5,76** / 8,75
07. **Varijanta $X_5Y_3Z_3$**	**9,10** / 8,90	**3,90** / 8,82	**6,99** / 8,77	**3,62** / 8,77
08. **Varijanta $X_6Y_4Z_2$**	**9,66** / 8,91	**3,97** / 8,82	**8,15** / 8,76	**3,64** / 8,77
09. **Varijanta $X_6Y_2Z_4$**	**9,66** / 8,91	**7,46** / 8,86	**8,24** / 8,79	**7,01** / 8,79
10. **Varijanta $X_8Y_4Z_4$**	**10,78** / 8,93	**5,26** / 8,84	**9,24** / 8,76	**4,80** / 8,77

S obzirom da su kod svih ispitivanih modela, uključujući i polazni praktični primjer, bila ista ograničenja kapaciteta i ostvarene gotovo identične profitne stope, razlika rezultata po različitim modelima optimiranja može se vidjeti na način da se dobiveni rezultati u planovima proizvodnje za svaku varijantu usporede sa stvarnom realizacijom iz praktičnih primjera.

Vidljivo je da su najbolji rezultati ostvareni primjenom diskretnog korektivnog dinamiziranog programiranja (model D) a da su vrlo dobri rezultati postignuti i dinamiziranim linearnim programiranjem zasnovanom na kliznom planiranju i praćenju bez korektivne optimizacije (model B). To ujedno potvrđuje da je uz metodu programiranja vrlo važan i gotovo odlučujući faktor sam način izvođenja procesa planiranja i praćenja proizvodnje.

Dobiveni rezultati ispitivanja modela optimiranja su nešto lošiji nego bi to bilo u praksi iz razloga što je rađeno s malim brojem proizvoda (grupe proizvoda) pa je bilo moguće dobiti manji broj varijanti korekcije planova. Osim toga, model oponašanja za ispitivanje nije imao finu podjelu mogućih kombinacija korekcije planova te nije imao ugrađenu mogućnost kombinatorike s pojedinačnim očekivanim i neočekivanim dodatnim narudžbama proizvoda već samo s njihovim sumama po svakom proizvodu.

Usporedbom rezultata ispitivanja za obje proizvodnje vidi se da su bolji rezultati dobiveni za proizvodnju autostakla jer su se korekcije kombinirale s više proizvoda i nešto je manja razlika gornjih i donjih granica potražnje, iako je učešće očekivanih i neočekivanih dodatnih narudžbi po postocima bio veći nego u primjeru proizvodnje posuđa.

Pri tome se može utvrditi minimalna razlika ostvarene profitne stope kod korektivnih modela optimizacije (B, C i D) u odnosu na polazni model linearnog programiranja (A). Ta se razlika kreće u rasponu 1-2% od ostvarenog, nominalnog profita i neizbježna je ako se želi koristiti prilagodljivi model planiranja proizvodnje. No, to istovremeno dokazuje da se i uz korektivno, prilagodljivo optimiranje može postići zadovoljavajući optimum proizvodnje, a uz maksimalno prilagođavanje promjenama i poremećajima u okruženju.

Promatrajući grafičke prikaze na slikama 31., 32., 33. i 34. može se vidjeti da kod modela A konstantno raste odstupanje količina što je u varijanti ispitivanja veći postotak očekivanih i neočekivanih dodatnih narudžbi. Slična promjena rezultata može se vidjeti i kod modela C samo što su odstupanja količina manja.

Drugačiji grafički prikaz kretanja rezultata možemo utvrditi kod modela B i D jer se kod njih kliznim planiranjem planovi stalno usklađuju s promjenama. Pri tome se bolji rezultati dobivaju kada je veće učešće očekivanih dodatnih narudžbi, tj. onih narudžbi koje su na vrijeme uključene u planove putem kliznog planiranja, uz osjetno manja odstupanja količina.

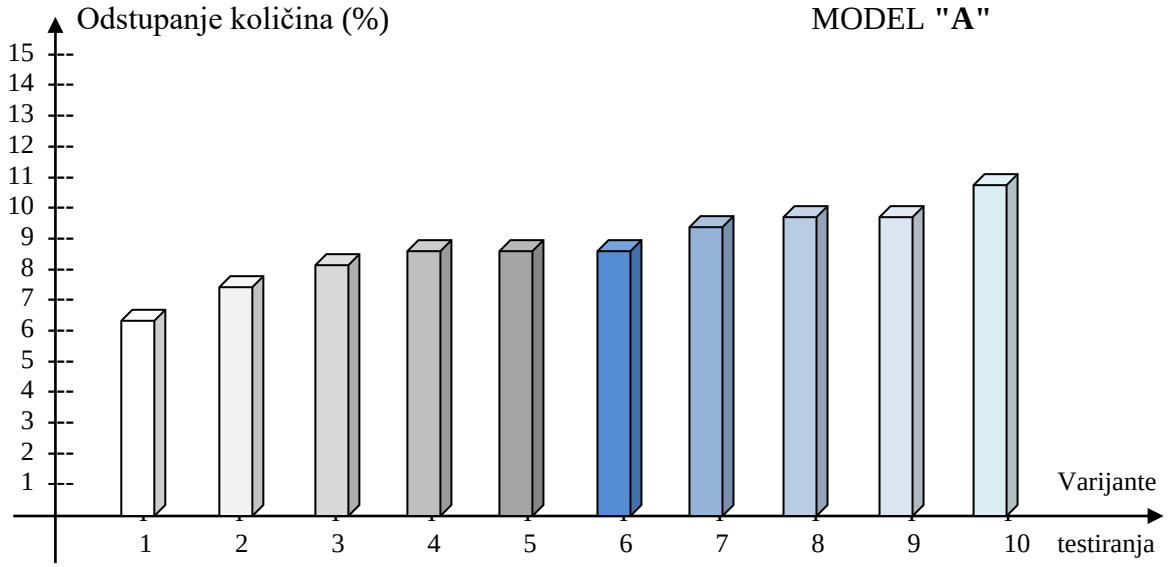

Slika 31. *Prikaz odstupanja količina po varijantama ispitivanja za model* ***A***

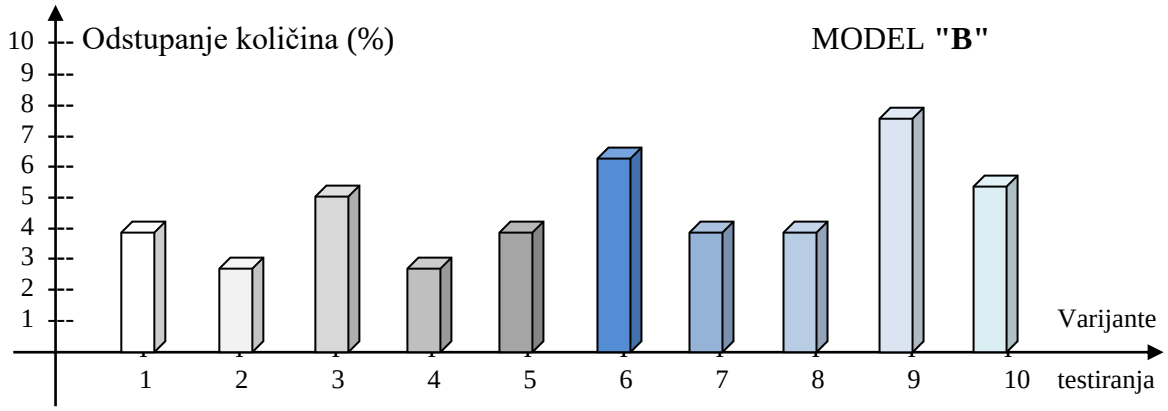

Slika 32. *Prikaz odstupanja količina po varijantama ispitivanja za model* ***B***

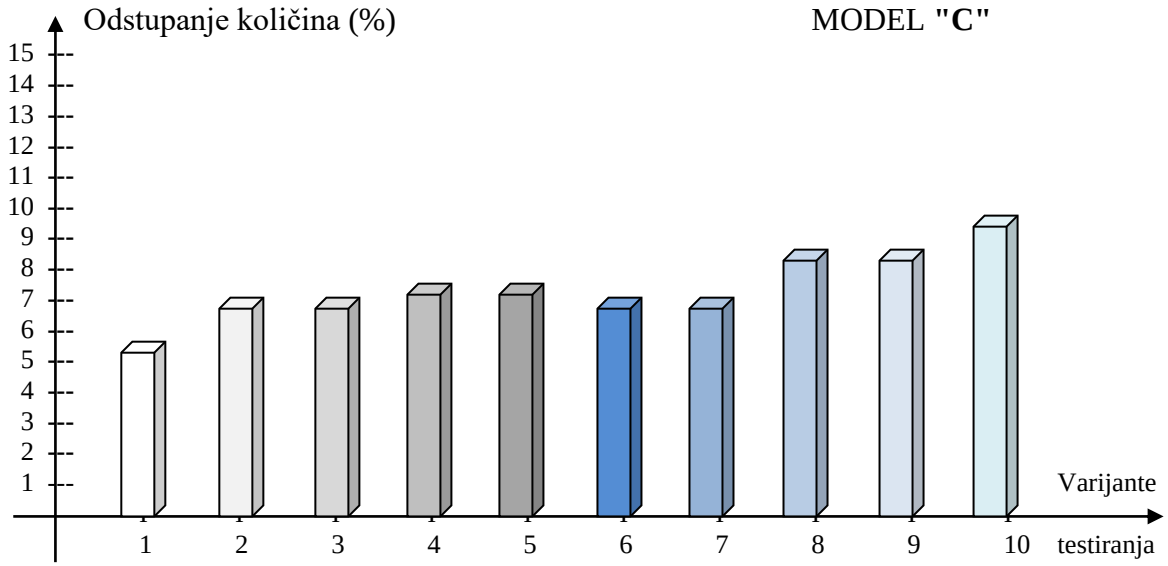

Slika 33. *Prikaz odstupanja količina po varijantama ispitivanja za model* ***C***

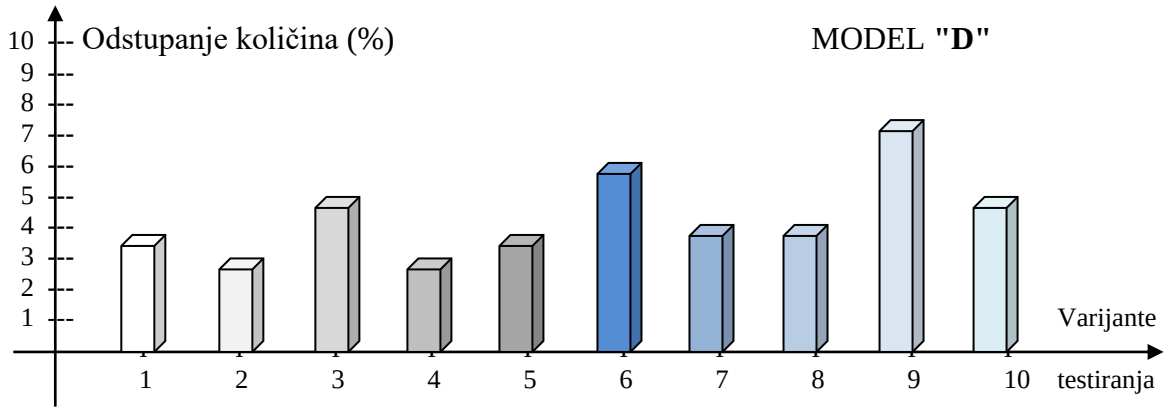

Slika 34. *Prikaz odstupanja količina po varijantama ispitivanja za model **D***

Da bi se ocijenila ukupna osjetljivost planiranja proizvodnje, izračunato je po svakom modelu optimiranja prosječno odstupanje količina ΔQ_i i profitne stope PF_i za sve varijante kod ispitivanja u proizvodnji posuđa i autostakla, kako je prikazano u tablici 27.

Tablica 27. *Odstupanja količina i profitne stope po ispitivanim modelima i proizvodnjama*

	Posuđe I (%)		**Autostaklo II** (%)	
a. Model **A**	$(\Delta Q_A)_I$ =11,07	$(PF_A)_I$ = *11,51*	$(\Delta Q_A)_{II}$ = 8,65	$(PF_A)_{II}$ = *8,90*
b. Model **B**	$(\Delta Q_B)_I$ = 6,48	$(PF_B)_I$ = *11,47*	$(\Delta Q_B)_{II}$ = 4,54	$(PF_B)_{II}$ = *8,83*
c. Model **C**	$(\Delta Q_C)_I$ = 9,82	$(PF_C)_I$ = *11,41*	$(\Delta Q_C)_{II}$ = 7,26	$(PF_C)_{II}$ = *8,77*
d. Model **D**	$(\Delta Q_D)_I$ = 5,84	$(PF_D)_I$ = *11,42*	$(\Delta Q_D)_{II}$ = 4,13	$(PF_D)_{II}$ = *8,77*

Može se utvrditi da je primjenom modela D, tj. diskretnog korektivnog dinamiziranog programiranja postignuto približno 2 puta manje odstupanje količina u odnosu na model A, 1,7 puta manje u odnosu na model C te 10% manje nego kod primjene modela B, uz zanemarive razlike ostvarenih profitnih stopa.

Potvrđuje se da je vrlo važno imati na vrijeme dovoljan broj pouzdanih ulaznih informacija za izradu operativnih planova proizvodnje kako bi razlika između donje i gornje očekivane granica potražnje bila što manja. Također je važno da proizvodni sustav bude što fleksibilniji i prilagodljiviji kako bi se očekivane i neočekivane dodatne narudžbe u što većoj mjeri i na što efikasniji način uključile u aktualne operativne planove proizvodnje.

Ispitivanje modela rađeno je na pojednostavljeni način i na malom primjeru, s malim brojem proizvoda i pripadajućim podacima pa bi ga prije razrade i primjene bilo dobro ispitati i na izvornim primjerima, s većim brojem proizvoda i različitim uvjetima rada.

Naime, realnije bi bilo da su granice u varijanti klasičnog linearnog programiranja bile nešto uže pa bi i odstupanje po proizvodima između planiranih i realiziranih količina, prikazano u tablicama 25. i 26., bilo manje. Isto tako je realno i da bi kod varijante linearnog programiranja s korektivnim optimiranjem putem oponašanja bilo više korekcija, a time bi i razlike planiranih i realiziranih količina bile nešto manje, ali uz veće troškove korekcija.

Prema dobivenim rezultatima ispitivanja utvrđuje se da je model diskretnog korektivnog dinamiziranog programiranja u izradi optimalnih planova proizvodnje onaj model koji osigurava značajnu prilagodljivost proizvodnje promjenama, poremećajima i rizicima u okruženju i samom proizvodnom sustavu, uključujući pravovremene promjene po pitanju potrebnih resursa za proizvodnju.

Također se može zaključiti da taj model prilagodljivog planiranja i praćenja proizvodnje, kao i drugi modeli optimiranja u uvjetima neizvjesnosti-promjena, neće uvijek osigurati rješenja sa 100% maksimalnim rezultatima po odabranim kriterijima. No, to će svakako omogućiti da se proizvodni sustav prilagođava promjenama i objektivnim situacijama uz najmanja odstupanja od polaznih rješenja, odnosno maksimalno mogućih rezultata, bolje i jednostavnije nego je to kod primjene poznatih sličnih modela.

Izvršena ispitivanja rađena su do slučajeva kada je očekivanih i neočekivanih dopunskih narudžbi bilo i do 70%, uz različite odnose tih grupa narudžbi, te pokazuju da je model D, diskretnog korektivnog dinamiziranog programiranja, kao i model B dinamiziranog linearnog programiranja, najpovoljnije koristiti u sljedećim slučajevima:

1. U serijskoj proizvodnji gdje se kombinirano radi za zalihe i po narudžbi
2. U slučaju većeg postotka dopunskih narudžbi s rokovima koji se mogu uključiti u korekcije polaznih planova kliznim planiranjem i praćenjem
3. U slučaju kada je učešće očekivanih i neočekivanih dodatnih narudžbi po prilici podjednako

Ovdje je još važno napomenuti da bi slične rezultate dobili kada bi u ispitivanje modela uključili i negativne promjene, odnosno poremećaje u proizvodnom sustavu – zastoje zbog kvarova, nedostatak materijala i energenata, otkazivanje narudžbi i sl. Tada bi se korekcije radile s obrnutim predznakom, a polazni operativni plan imao bi nižu donju granicu potražnje i osjetno nižu gornju granicu potražnje, usklađeno s raspoloživim resursima za proizvodnju.

7.3. Postupak određivanja planiranja i praćenja

U uvodnom dijelu ovog istraživanja je navedeno da će se rad temeljiti na procesnom sagledavanju i istraživanju planiranja i praćenja proizvodnje pa će se kao zadnji dio prijedloga zasnovanih na dobivenim rezultatima opisati postupak određivanja planiranja i praćenja.

Ako se promotre postavljeni ciljevi i očekivani doprinos ovog istraživanja iz poglavlja 2.5. na stranici 29, iz dosadašnjeg materijala se može vidjeti da su oni ostvareni i da preostaje odrediti postupak modeliranja i optimizacije planiranja i praćenja proizvodnje u različitim sustavima i uvjetima prema funkciji utjecajnih varijabli pripadajućeg sustava. Stoga se ovdje kao rezultat izvršenog znanstvenog istraživanja predlaže i ukratko opisuje postupak za određivanje procesa planiranja i praćenja proizvodnje koji bi trebao biti metodološki okvir za primjenu dobivenih spoznaja.

Svaki proizvodni sustav je specifičan po osnovu svoje strukture, sadržaja i načina rada, a posebno po obilježjima ljudi koji u njemu rade i po tome što se svaki nalazi u drugačijem okruženju i djeluje u drugačijim uvjetima. S druge strane, može biti više sličnih proizvodnih sustava koji će imati isti proizvodni program, istu tehnologiju-strojeve, koristiti iste metode i tehnike planiranja i optimiranja i td., tj. imati sličnu ili čak identičnu strukturu, ali zbog svih ostalih obilježja sustava i njegove okoline neće imati identične organizacijske procese pa tako ni proces planiranja i praćenja proizvodnje.

Postupak određivanja procesa planiranja i praćenja koji se ovdje predlaže trebao bi uzeti u obzir prethodno navedeno pa se može definirati po fazama kako slijedi:

01. Snimanje i analiza postojećeg procesa i pokazatelja planiranja i praćenja proizvodnje

02. Provjera mogućnosti korištenja predloženih kriterija i mjerila za ocjenjivanje procesa planiranja i praćenja proizvodnje i eventualna izmjena i dopuna istih

03. Utvrđivanje i ocjenjivanje izabranih utjecajnih faktora na proces planiranja i praćenja proizvodnje

04. Istraživanje i ispitivanje procesa planiranja i praćenja proizvodnje s obzirom na povezane procese i moguće druge nivoe po odabranim utjecajnim faktorima

05. Analiza i ocjenjivanje rezultata istraživanja i ispitivanja procesa planiranja i praćenja proizvodnje sukladno mogućim promjenama nivoa utjecajnih faktora

06. Modeliranje i oblikovanje rješenja procesa planiranja i praćenja proizvodnje

07. Izbor, definiranje i testiranje metode oponašanja i kriterija za primjenu u izradi korekcija operativnih planova proizvodnje primjenom kliznog planiranja i praćenja

08. Izbor metode i tehnike dinamičkog programiranja za određivanje polaznih planova proizvodnje i povezivanje s tehnikom oponašanja za korekciju planova

09. Razrada i oblikovanje cjelokupnog procesa prilagodljivog planiranja i praćenja proizvodnje s potrebnim software-om i pomagalima

10. Izrada potrebne ulazne i izlazne dokumentacije s cjelokupnim procesom prikupljanja, prerade i obrade informacija s potrebnim propisima i uputama za rad

U **prvoj fazi** predloženog postupka snimanjem treba se utvrditi postojeće stanje procesa planiranja i praćenja proizvodnje sa svim njegovim pokazateljima, kao i svi relevantni pokazatelji o njegovom odvijanju i rezultatima. Tu je posebno važno uočiti sve detalje izvođenja tog procesa a posebno onih dijelova gdje se događaju veze i povezivanje s drugim procesima neposredno povezanim i važnim za odvijanje procesa planiranja i praćenja.

Prema načinu i intenzitetu izvođenja procesa planiranja i praćenja te pokazateljima ostvarenih rezultata moguće je utvrditi probleme u tom procesu i njihove posljedice. Pri tome je vrlo bitno uočiti iz kojih segmenata, ne samo procesa planiranja i praćenja nego i ostalih procesa, dolazi do poremećaja i kako isti utječu na rezultate i pokazatelje uspješnosti.

Snimanje i analiza postojećeg stanja procesa planiranja i praćenja obuhvaća i pripadajući informatički proces u smislu načina prijenosa i obrade informacija, korištenih metoda i tehnika rada, algoritama, software-a i pripadajućih pomagala.

Druga faza postupka predstavlja izbor kriterija i mjerila za ocjenjivanje procesa planiranja i praćenja i donošenje odluka kako bi se unaprijed znalo prema čemu će se ocijenjivati uspješnost tog procesa.

Osim toga, izborom kriterija i mjerila određuju se podaci i pokazatelji koji će se ubuduće pratiti i za koje treba odrediti način budućeg prikupljanja, odnosno obrade. U tu svrhu se mogu koristiti kriteriji i mjerila koja su korištena u ovom istraživanju, a koja se mogu dijelom izmijeniti ili dopuniti, sukladno potrebama i mogućnostima proizvodnog sustava.

Za pouzdano korištenje predloženih kriterija i mjerila potrebno je provjeriti da li se oni mogu koristiti po predloženim algoritmima ili je potrebno preurediti njihov odnos u okviru sintetskog kriterija, a što se najbolje može ocijeniti usporedbom troškova rada u procesu planiranja i praćenja, troškova reklamacija, zbog gubitaka u isporukama i troškova zaliha.

Ako proizvodni sustav radi s malim zalihama imati će visoku ocjenu po kriteriju U_3 – efikasnost upravljanja zaliha, a troškovi zaliha biti će niži od prethodne dvije grupe troškova, ocjene po kriteriju U_3 treba uzeti u visini drugog korjena dobivene vrijednosti tog pokazatelja.

Tada će se sintetski kriterij U računati po izrazu (63), kako slijedi:

$$U = U_3 \cdot U_3 \cdot \sqrt{U_3} \tag{63}$$

U osnovi, svaki sustav treba kriterije po kojima će ocjenjivati proces planiranja i praćenja proizvodnje odrediti sukladno odnosima parametara koji ga definiraju, iako je poželjno koristiti jedinstvene kriterije zbog usporedbe s drugima.

U **trećoj fazi** postupka potrebno je utvrditi i ocijeniti utjecajne faktore na proces planiranja i praćenja, sukladno rezultatima i postavkama iz prethodne dvije faze ovog postupka. To znači da je potrebno analitički odrediti koji su to faktori i kako najviše utječu na uspješnost procesa planiranja i praćenja i prema odabranim kriterijima odrediti jačinu njihovog djelovanja. Tim dijelom rada ujedno će se odmah moći ocijeniti mogućnosti poboljšanja, odnosno promjena djelovanja utjecajnih faktora, a to znači i raspoložive varijante rješenja.

Ovdje je jako važno odrediti koji su to dijelovi organizacijskih procesa najznačajniji u svojem djelovanju i na koji način djeluju pošto se ovdje zasigurno radi o zajedničkom djelovanju većeg broja faktora. Također je važno odrediti kako vrste proizvoda i ukupan asortiman utječu na proces planiranja i praćenja, kakav je značaj i utjecaj tehnologije i njene kvalitete, kako na uspješnost procesa planiranja i praćenja utječe npr. transport itd.

Iako na proces planiranja i praćenja proizvodnje utječe veći broj faktora, zasigurno se može tvrditi da će svakako trebati tretirati sljedeće faktore na 1. i 2. nivou, kako slijedi:

1. **Oblik plasmana** 1. nivo – većinom za zalihe
   2. nivo – većinom po narudžbi
2. **Način planiranja** 1. nivo – kalendarski
   2. nivo – klizno planiranje i intenzivno prikupljanje podataka
3. **Učestalost i vrijeme trajanja zastoja strojeva i opreme**
   1. nivo – postojeće stanje
   2. nivo – moguće, poboljšano stanje
4. **Učestalost i vrijeme trajanja zastoja ljudi**
   1. nivo – postojeće stanje
   2. nivo – moguće, poboljšano stanje

Eventualni 5. faktor za tretiranje može se odrediti ovisno o specifičnim utjecajima i uvjetima u tretiranom proizvodnom sustavu.

Istraživanje i ispitivanje procesa planiranja i praćenja proizvodnje obzirom na povezane procese i moguće druge nivoe po odabranim utjecajnim faktorima kao **četvrta faza** postupka sastoji se od ispitivanja veza s drugim procesima i ispitivanja više kombinacija najvažnijih utjecajnih faktora u svojem djelovanju na uspješnost procesa planiranja i praćenja.

Utvrđivanje povezanosti i međusobnog utjecaja organizacijskih procesa koji svojim aktivnostima i rezultatima neposredno utječu na uspješnost planiranja i praćenja proizvodnje je preduvjet za daljnje istraživanje djelovanja utjecajnih faktora. Tu je izuzetno važno napraviti kompletnu analizu veza procesa putem analize informacijskih podprocesa koji se između njih odvijaju, kako po pitanju sadržaja informacija tako i po pitanju njihove obrade i posebno donošenja odluka temeljem odgovarajućih informacija.

Najjednostavniji način istraživanja i ispitivanja je ono pojedinačno po svakom faktoru s procjenom očekivanih rezultata, a najsigurniji i najtočniji način je korištenjem metode i tehnika oponašanja. Pri tome se moraju odrediti realni dosezi utjecaja svakog faktora, odnosno oni koje je realno postići u kraćem roku, a razvojnim programima trebaju se utvrditi njihove značajnije promjene utjecaja, u smislu pozitivnog djelovanja na uspješnost planiranja i praćenja proizvodnje.

Jedna od bitnih odrednica za izbor istraživanja i ispitivanja biti će sami karakter proizvodnje u smislu načina rada za tržište i veličina serija te odabrane varijante modela planiranja i praćenja s pripadajućim algoritmima, metodama i tehnikama rada.

Odnosi između djelovanja pojedinog utjecajnog faktora i njihovih interakcija sigurno će se pokazati primjenom plana pokusa za što će sigurno trebati pripremiti pouzdane potrebne podatke te imati odgovarajući model oponašanja.

Analiza i ocjenjivanje rezultata istraživanja i ispitivanja procesa planiranja i praćenja proizvodnje sukladno mogućim promjenama nivoa utjecajnih faktora predstavlja **petu fazu** postupka određivanja procesa planiranja i praćenja. Tu se svakako podrazumijeva korištenje analize varijance a za dodatnu preciznost poželjno je primijeniti i regresijsku analizu.

U slučaju da su prethodno napravljena dva ili više modela faktorskog plana pokusa, za svaki zasebno treba napraviti i analizu varijance te usporediti dobivene rezultate. Kako se u analizi varijance ocjenjuje na bazi dva nivoa odabranih faktora istog skupa, dobiveni rezultati pokazati će pouzdano razlike utjecaja po faktorima i njihovim interakcijama.

Ako promjena nivoa u načinu planiranja i praćenja ne pokaže značajniji utjecaj, svejedno će biti potrebno dovršiti ovaj postupak određivanja procesa planiranja i praćenja, samo što će naglasak biti na definiranju rješenja po onim faktorima koji su se pokazali najvažnijim.

Šestu fazu rada predstavlja modeliranje procesa planiranja i praćenja što podrazumijeva definiranje i oblikovanje tog procesa po vremenskom obuhvatu i dinamici, uključujući i veze s procesima s kojima je proces planiranja i praćenja proizvodnje po određenim aktivnostima čvrsto povezan. To znači da se za modeliranje trebaju definirati detalji rješenja svih utjecajnih faktora koju su se u prethodnim fazama rada pokazali najznačajniji.

Model kliznog planiranja i praćenja odrediti će, definiranjem dužine svih planskih razdoblja i vremenskog razmaka u klizanja svakog nivao planiranja, a na bazi utvrđenog načina proizvodnje i prodaje, kompleksnosti proizvodnje, broja serija-isporuka te rješenja djelovanja glavnih utjecajnih faktora. To uključuje i određivanje svih parametara kojima se pokazuje veličina i intenzitet promjena u okruženju i samom proizvodnom sustavu.

Posebno je značajno da se prilikom modeliranja procesa planiranja i praćenja precizno odrede veze između procesa zbog povezanog i usklađenog djelovanja cijelog sustava. Još je važno napomenuti da prateći informacijski podproces treba biti sastavni dio svih aktivnosti svakog uključenog procesa. Određivanje veza između povezanih procesa treba određivati sukladno određenom intenzitetu kliznog planiranja i praćenja, odnosno pouzdanosti proizvodnje, prodaje, nabave i samog procesa planiranja i praćenja.

Ovdje pripada i utvrđivanje svih nivoa planova, kako operativnih tako i strateških, sa svim sadržajima te elementima temeljem kojih će se moći pratiti uspješnost planiranja i praćenja proizvodnje ali i drugih procesa u sustavu.

U **sedmoj fazi** rada se obavlja izbor, definiranje i testiranje metode oponašanja i kriterija za primjenu u izradi korekcija operativnih planova proizvodnje primjenom kliznog planiranja i praćenja. Danas postoji više metoda i tehnika oponašanja pa se samo postavlja pitanje odgovarajućeg izbora iako je s obzirom na specifičnosti svakog poslovnog sustava za očekivati da će svaki razvijati sebi primjeren model oponašanja. Pri tome se mogu koristiti kriteriji optimizacije korekcije planova koji su predloženi u ovom istraživanju ili uzeti neke druge obzirom na ciljeve poslovnog sustava.

Izbor metode i tehnike dinamičkog programiranja za određivanje polaznih planova proizvodnje i povezivanje s odabranom tehnikom oponašanja za korekciju planova predstavlja **osmu fazu** rada u postupku određivanja procesa planiranja i praćenja proizvodnje. Definira se odgovarajuća metoda i tehnika dinamičkog programiranja-optimiranja za određivanje polaznih planova proizvodnje, a za očekivati je da će se nabaviti gotov program prilagođen poslovnom sustavu.

Iskustvo pokazuje da razvijeni programi za optimiranje traže odgovarajuće pripreme sustava u smislu potrebnih podataka za njihovu primjenu, a gotovi paketi software-a zahtijevaju dodatni software za prilagodbu, uključujući i povezivanje sa prethodno definiranim modelom oponašanja i pripadajućim software-om.

Kriteriji optimizacije također mogu biti promjenjivi od sustava do sustava, zavisno od ciljeva, uvjeta i vremena u kojima proizvodni sustav djeluje.

Naravno, prethodno treba detaljno ustrojiti sustav prijenosa i obrade informacija tako da iste budu pravovremeno i u cijelosti dostupne za korištenje odabranih i instaliranih metoda i tehnika optimiranja.

Proces optimiranja, kako polaznog tako i korektivnog, treba zasnivati na realnim mogućnostima sustava i rezultirati rješenja koja će se sa sigurnošću moći realizirati. Poželjno je da rezultati optimizacije proizvodnje budu maksimalno usklađeni s optimizacijom svih resursa, ne samo proizvodnje već i ukupnog poslovanja sustava. Kako razvijeni model ERP ima naglasak na integriranju svih podataka iz svih procesa u ujedinjeni sustav sa unificiranom bazom podataka za različite module softwarea, diskretno korektivno dinamizirano optimiranje kao model prilagodljivog planiranja i praćenja moglo bi biti sastavni dio ERP-a.

U **devetoj fazi** postupka treba izvršiti razradu i oblikovanje cjelokupnog procesa prilagodljivog planiranja i praćenja proizvodnje s potrebnim software-om i pomagalima i isto uobličiti u jedinstveni proces planiranja i praćenja, sa svim detaljno razrađenim aktivnostima svake faze primjene odabranog procesa planiranja i praćenja, vezama s ostalim procesima i načinima koordiniranja i usklađivanja svih procesa uključenih u ukupni proces planiranja i praćenja.

To nadalje treba uključiti sve potrebne algoritme optimiranja i odlučivanja, potrebnu radnu dokumentaciju, posebno oblik planova i izvještaja, način prijenosa i obrade informacija te ocjenjivanje postignutih rezultata.

Zadnja, **deseta faza** obuhvaća izradu potrebne ulazne i izlazne dokumentacije s cjelokupnim procesom prikupljanja, prerade i obrade informacija s potrebnim propisima i uputama za rad i zapravo je priprema za sprovođenje razrađenog i u cijelosti oblikovanog procesa planiranja i praćenja proizvodnje.

Za svaki pojedini podproces, pa čak i njihove faze rada, potrebno je razraditi sve upute i organizacijske propise zbog jednoznačnosti procesa planiranja i praćenja.

Pri tome proces planiranja i praćenja, odnosno njegovi odgovarajući dijelovi moraju biti ukomponirani u jedinstveni sustav upravljanja proizvodnjom i poslovanjem.

Ovdje je također bitno istovremeno uključiti i potrebne aktivnosti praćenja odvijanja i rezultata procesa planiranja i praćenja kako bi se kontinuirano moglo raditi na usavršavanju tog procesa. Istovremeno, sva detaljna zapažanja i postignuti rezultati dobra su podloga za rad na razvoju ukupnog proizvodnog sustava, odnosno rad na razvoju putem Lean pristupa ili nekog drugog načina rada na ukupnom razvoju.

Naravno, ovaj kratko opisani postupak određivanja planiranja i praćenja traži za svoje preciziranje detaljnu razradu svih ovdje navedenih faza rada, a posebno ako se ide na njegovu primjenu u konkretnom proizvodnom sustavu.

7.3. Zaključak o istraživanju

Ovo je istraživanje izvedeno u skladu sa znanstvenim istraživanjima u svijetu u zadnjih 10 godina, a u kojima se istražuju i oblikuju modeli planiranja i praćenja proizvodnje u uvjetima neizvjesnosti i promjena te specifičnim vrstama i tipovima proizvodnje kao što su proizvodnja po narudžbi, pojedinačna proizvodnja i sl. Radi se o prijedlozima modela optimiranja proizvodnje po raznim kriterijima uz sve veću primjenu modela oponašanja kao najpovoljnijeg rješenja za brojne specifične uvjete proizvodnje i neizvjesnost.

No, niti u jednom od znanstvenih radova autori se ne bave samimim procesom, načinom rada na planiranju i praćenju proizvodnje niti ima radova koji bi putem odgovarajućih kriterija i mjerila mogli utvrditi kolika je uspješnost procesa planiranja i praćenja proizvodnje.

U ovom je istraživanju prvi puta znanstveno obrađen proces planiranja i praćenja proizvodnje te je predložen odgovarajući postupak modeliranja i određivanja tog procesa uz originalni model korektivne optimizacije planova proizvodnje, kako slijedi:

1. Uz primjenu priznatih znanstvenih metoda istraživanja kao što su faktorski plan pokusa, metoda oponašanja, analiza varijance i regresijska analiza, ovo je istraživanje pokazalo da će uspješnost planiranja i praćenja, pa time i uspješnost cijelog proizvodnog sustava, značajno ovisiti o načinu rada na planiranju i praćenju proizvodnje, a ne samo o odabranoj metodi optimiziranja planova proizvodnje.

U tu svrhu definirani su novi, originalni kriteriji i mjerila, sintetski povezani, za ocjenjivanje uspješnosti planiranja i praćenja proizvodnje pomoću kojih se mogu ocjenjivati utjecajni faktori na proces planiranja i praćenja, uspoređivati uspješnost proizvodnog sustava u raznim razdobljima rada te raditi usporedbe po pitanju uspješnosti proizvodnje, odnosno njenog procesa planiranja i praćenja između različitih proizvodnih sustava jer su korištena mjerila bezdimenzionalna. Regresijska analiza putem funkcije regresije u poglavlju 6.3. pokazuje analogne utjecaje faktora i interakcija kao kod analize varijance, a F-test potvrđuje adekvatnost modela ispitivanja. To potvrđuje ispravnost obadva postupka kao i činjenicu da se faktorski plan pokusa s odgovarajućim modelom oponašanja može koristiti u postupku određivanja procesa planiranja i praćenja proizvodnje.

Kako se danas sve više nameće potreba optimiziranja poduzeća-sustava u smislu njegove prilagodljivosti i fleksibilnosti, a što potvrđuju i zadnja znanstvena istraživanja, odabrani kriteriji za ocjenu uspješnosti planiranja i praćenja egzaktno pokazuju koliko proizvodni sustav djeluje u smislu optimalnosti, prilagodljivosti i flesibilnosti.

Ako se pojedinačni kriteriji prema izrazima (1), (6) i (11) upišu u tom obliku u sintetski kriterij **U** prema izrazu (17) dobivamo iskaz uspješnosti planiranja i praćenja po izrazu (64)

$$U = [\left(1 - \frac{\sigma_{\bar{x}}}{\bar{x}}\right) \cdot (1 - \Delta\bar{x})] \cdot [\frac{R - R_z}{R} \cdot (1 - \bar{x}_z / \bar{x}_{DI})] \cdot [\frac{1}{1/2 \cdot (O_p + O_s)}] \quad (64)$$

Po izrazu (64) vidimo da elementi sinteskog kriterija imaju u sebi pokazatelje rada proizvodnje, prodaje, nabave i operativnog planiranja i praćenja proizvodnje pa se odabrani kriterij uspješnosti može objektivno koristiti za ocjenu optimalnosti, prilagodljivosti i flesibilnosti proizvodnog sustava.

Kao način rada u uvjetima neizvjesnosti i promjena, odnosno poremećaja i rizika, predložen je model kliznog planiranja i praćenja, a u poglavlju 6.5. predložen je način modeliranja procesa planiranja i praćenja proizvodnje i osnovni modeli kliznog planiranja i praćenja s obzirom na uvjete i tipove proizvodnje.

Model kliznog planiranja i praćenja proizvodnje omogućava da se pravovremeno i sustavno utvrđuju i usklađuju resursi za proizvodnju, ne samo za osnovni operativni plan već i za više operativne planove, što omogućava da proizvodni i poslovni sustav stječu veću prilagodljivost i fleksibilnost, kako u uvjetima pozitivnih tako i u uvjetima negativnih promjena u okruženju i samom sustavu.

2. Na modelu kliznog planiranja i praćenja proizvodnje izgrađen je model korektivnog dinamiziranog optimiranja planova proizvodnje gdje se primjenom linearnog programiranja uz periodičko usklađivanje u procesu kliznog planiranja i praćenja dobiva dinamizirano programiranje proizvodnje te se relativno jednostavno može primijeniti kod svake proizvodnje. Naime, poznato je da već nekoliko desetljeća nema odgovarajućeg algoritma za primjenu izvornog matematičkog modela dinamičkog programiranja pa se ono prevodi na linearno programiranje po nekoliko tipova odgovarajućih algoritmama. Zbog toga se predloženo dinamizirano programiranje zasnovano na kliznom planiranju i praćenju može smatrati još jednom tehnikom dinamičkog programiranja.

Uz dodavanje korektivnog optimiranja primjenom metode oponašanja postavljen je model diskretnog korektivnog dinamiziranog optimiranja s odgovarajućim kriterijima optimizacije i korekcije kao model koji na vrlo jednostavna način i uz veliku uspješnost omogućava prilagodljivost i fleksibilnost proizvodnog sustava u uvjetima neizvjesnosti i promjena. Modeli oponašanja za korekciju polaznih optimiziranih operativnih planova mogu biti različiti i prvenstveno ovise o karakteru proizvodnje te načinu proizvodnje – za zalihe, po narudžbi, kombinirano, pojedinačno i dr., i mogu dati rezultate iz skupa optimalnih rješenja.

Naime, kod matematičkog optimiranja zadan je sustav od ***m*** jednadžbi i ***n*** nepoznanica,

$$\sum_{k=1}^{n} \alpha_{ik}\, \xi_k = \beta_i \qquad (i=1, \ldots\ldots, m) \tag{65}$$

gdje su α_{ik}, ξ_k i β_i kao parametri proizvodnje konstante i realni brojevi, te linearna forma

$$f(\boldsymbol{x}) = \sum_{k=1}^{n} \gamma_k\, \xi_k \tag{66}$$

Treba naći vektor $\boldsymbol{x} = \xi_1, \ldots\ldots, \xi_k) \geq 0$ koji linearnu formu $\boldsymbol{f\ (x)}$ čini maksimalnom i zadovoljava sustav jednadžbi **A x** = **b** pa je svaki vektor $\boldsymbol{x_o}$ koji zadovoljava navedene uvjete optimalno riješenje.

Prema podacima iz tablice 26. s rezultatima ispitivanja modela optimizacije na praktičnom primjeru vidljivo je zanemarivo odstupanje od početnog optimuma. Stoga se može reći da korektivno optimiranje ima zanemarivo odstupanje od funkcije maksimuma pa se tako dobiveno rješenje može smatrati elementom skupa svih mogućih riješenja **Ax=b, x ≥0**.

Korektivno optimiranje se primjenom metode oponašanja izvodi prema kriteriju po izrazu EK = IPP – PT (47) gdje je efikasnost korekcije plana EK razlika produkta indeksa promjene prihoda IP i profita IF i promjene troškova planiranja PT. Na taj način obuhvaća se značaj djelovanja svih tretiranih procesa – proizvodnje, nabave, prodaje i operativnog planiranja i praćenja proizvodnje, tako da se ovim kriterijem pronalazi ne samo optimalno rješenje plana proizvodnje već i optimalnost, prilagodljivosti i flesibilnosti proizvodnog sustava.

3. Temeljem prethodno navedenih rezultata istraživanja predložen je postupak određivanja procesa planiranja i praćenja proizvodnje i korektivnog optimiranja planova proizvodnje u 10 faza rada, kako je to prikazano u poglavlju 7.3.

U poglavlju 7.2. izvršeno je ispitivanje predloženog modela korektivnog optimiranja na način da je na praktičnim primjerima izvršena usporedba tog modela s nekim drugim modelima optimiranja i koja je pokazala prednosti modela diskretnog korektivnog dinamiziranog optimiranja u navedenim uvjetima. Za očekivati je da će za različite tipove i uvjete proizvodnje primjena diskretnog korektivnog dinamiziranog optimiranja davati različite, ali dobre rezultate u smislu preciznosti optimiranja, ovisno o uvjetima optimiranja.

Prema rezultatima istraživanja i testiranja modela diskretnog korektivnog dinamiziranog optimiranja procjenjuje se da će se najbolji rezultati pokazati u slučajevima kombinirane proizvodnje za zalihe i po narudžbi te za serijsku proizvodnju po narudžbi.

Kod proizvodnje za zalihe i uz primjenu liearnog programiranja, kliznim planiranjem i praćenjem kontinuirano se putem istraživanja tržišta okvirno korigiraju gornje Q_{ij}^{g} i donje Q_{ij}^{d} granice očekivane potražnje za procjenjene količine promjene potražnje Qd_{ij}.

U slučaju kombinirane proizvodnje, za zalihe i po narudžbi, i polazni planovi i njihove korekcije obavljaju se preciznije. Polazni planovi određeni linearnim programiranjem se zapravo dva puta usklađuju i korigiraju – kliznim planiranjem i praćenjem kontinuirano se korigiraju i usklađuju gornje Q_{ij}^{g} i donje Q_{ij}^{d} granice očekivane potražnje temeljem prethodno prikupljenih očekivanih dodatnih narudžbi Qd_{ij}. Na osnovi izvanrednih, neočekivanih dodatnih narudžbi Qv_{ij} putem metode oponašanja i odabranih kriterija izvodi se korekcija aktualnog operativnog plana proizvodnje, odnosno, polazne planske količine proizvoda Q_{ij}^{p} korigiraju se na količine $(Q_{ij}^{p})'$. Time se postiže veća točnost planova proizvodnje, a time imamo i veću prilagodljivost sustava prema promjenama.

U serijskoj proizvodnji prema narudžbama polazni operativni planovi proizvodnje rade se optimiranjem putem linearnog programiranja ili metodom oponašanja gdje je funkcija optimuma $\Phi = \Phi\ (FO_{max})$ najčešće zasnovana na maksimalnom profitu, prihodu ili zauzetosti kapaciteta. I ovdje se mogu korigirati optimalni polazni planovi Q_{ij}^{p} temeljem novih narudžbi Qn_{ij} u nove količine $(Q_{ij}^{p})'$. U tom slučaju bitno je i terminiranje proizvodnje kako bi se uskladili ne samo prethodno zauzeti kapaciteti već se moraju održati i predviđeni, ugovoreni rokovi isporuke, osim ako ih nije moguće mijenjati u dogovoru s kupcima.

Nešto manja efikasnost navedene metode može biti kod proizvodnje za zalihe, jer nema posebnih narudžbi proizvoda, a u pojedinačnoj proizvodnji ne bi bilo puno efekata jer je tada najvažnije terminiranje proizvodnje po pojedinačnim nalozima.

Ako za ocjenu prilagodljivosti koristimo kriterij prilagodljivosti $PG = \Sigma\Delta Q_i / p$, prema izrazu (57) gdje je $\Sigma\Delta Q_i$ – razlika planiranih i realiziranih količina u decimalno iskazanom postotku a p – broj tretiranih grupa proizvoda, uz uvjet maksimalnog iskorištenja kapaciteta i rasta profitne stope kod korekcije polaznih planova, može se očekivati da će model prilagodljivog planiranja i praćenja u raznim načinima proizvodnje – za zalihe, po narudžbi i kombinirano, dati rezultate u sljedećem omjeru (67)

$$(PG)_{zal.} < (PG)_{nar.} < (PG)_{komb.} \qquad (67)$$

No, zasigurno se može reći da navedeni model diskretnog korektivnog dinamiziranog optimiranja daje veću uspješnost procesa planiranja i praćenja proizvodnje u smislu prilagodljivosti i fleksibilnosti proizvodnog sustava u uvjetima neizvjesnosti i promjena.

Može se očekivati da će u slučaju negativnih promjena – otkazivanja narudžbi, nedostatka repromaterijala i energenata, smanjenja kapaciteta zbog kvarova i dr., doći do manjeg smanjenja profita i povećanja troškova, ali se to može nadoknađivati u sljedećim razdobljima korekcije jer će planovi višeg reda biti bolje usklađeni s okruženjem.

Analizirajući ostvarenost postavljenih ciljeva istraživanja iz poglavlja 2.5. može se potvrditi sljedeće:

A. Tretirani utjecajni faktori koji djeluju na uspješnost planiranja i praćenja značajni su za veći dio vrsti i tipova proizvodnje pri čemu način planiranja i praćenja ima vrlo važan značaj. Da li će u nekom proizvodnom sustavu neki od predloženih i tretiranih utjecajnih faktora biti manje ili više značajni nego u korištenom praktičnom primjeru, ovisiti će o samom proizvodnom sustavu i njegovom okruženju. No, prema rezultatima analize varijance i regresijske analize za tretirani praktični primjer i modificiranim primjerima u poglavljima 5.7. i 6.1. može se očekivati da način planiranja i praćenja proizvodnje značajno utječe na uspješnost tog procesa i same proizvodnje.

B. Ovo je istraživanje dalo prijedlog univerzalnih kriterija i mjerila za određivanje uspješnosti procesa planiranja i praćenja proizvodnje, a koji se mogu koristiti u svakom proizvodnom sustavu. Također se mogu koristiti za usporedbu uspješnosti proizvodnog sustava po razdobljima (godinama), a moguće je njihovo korištenje za usporedbu s drugim proizvodnim sustavima, bez obzira na veličinu i djelatnost.

Kriteriji i mjerila za ocjenjivanje uspješnosti planiranja i praćenja do sada nisu razrađivani niti primjenjivani u znanosti i praksi, a naročito su važni za ocjenjivanje prilagodljivosti procesa planiranja i praćenja promjenama u okruženju i samom sustavu.

C. Istraživanjem je ostvaren i treći postavljeni cilj, a to su osnove za modeliranje fleksibilnog i prilagodljivog procesa planiranja i praćenja proizvodnje za razne tipove i uvjete proizvodnje. Uz to je predložen i model diskretnog korektivnog dinamiziranog optimiranja koji je prilagođen za primjenu u uvjetima neizvjesnosti i promjena.

Model je ispitan u usporedbi s nekoliko drugih modela optimiranja gdje je utvrđeno da se njegovom primjenom mogu očekivati bolji i prilagodljiviji rezultati nego kod postojećih modela optimiranja u uvjetima neizvjesnosti i promjena.

Također se pokazalo da izbor modela procesa planiranja i praćenja proizvodnje i metoda diskretnog korektivnog dinamiziranog optimiranja značajno utječu na uspješnost i prilagodljivost proizvodnog sustava čime je potvrđena hipoteza ovog istraživanja.

Hipoteza istraživanja je i matematički dokazana u poglavlju 7.1., bez obzira što je prilagodljivost proizvodnog sustava u odnosu na promjene u samom sustavu i njegovom okruženju uvijek djelomična, manje ili više, kako zbog brojnih ograničenja tako i zbog tromosti proizvodnog sustava. No, potvrđeno je da će kod primjene diskretnog korektivnog dinamiziranog optimiranja planovi svih nivoa biti objektivniji i bliži realnosti nego kod bilo kojeg drugog modela optimiranja u procesu planiranja i praćenja proizvodnje.

Navedeni matematički dokaz hipoteze ovog istraživanja također pokazuje kako je tek s korektivnim optimiranjem putem oponašanja moguće ostvariti prilagodbu stvarnim uvjetima u okruženju i samom sustavu. Iako se radi o traženju najpovoljnijeg riješenja od mogućih i dobivanju realnijih rješenja uz manja odstupanja od stvarnih uvjeta optimiranja planova proizvodnje, izvršena ispitivanja su pokazala zadovoljavajuće postizanje gotovo optimalnog rezultata po kriteriju optimizacije. Drugim riječima, modeli diskretnog korektivnog dinamiziranog optimiranja ne prilagođavaju stvarnost matematičkoj metodi već se matematičke metode prilagođavaju postizanju veće realnosti rješenja planova proizvodnje.

Izvršeno istraživanje dalo je i očekivani znanstveni doprinos primijenjenim znanstvenim metodama faktorskog plana pokusa, oponašanja, analizom varijance i regresijskom analizom u postupku istraživanja procesa planiranja i praćenja proizvodnje, određivanja i vrednovanja utjecajnih faktora kao osnove za izbor modela procesa planiranja i praćenja proizvodnje i metode optimiranja planova proizvodnje u uvjetima neizvjesnosti i promjena.

Znanstvenim doprinosom može se smatrati i prijedlog kriterija i mjerila za ocjenjivanje uspješnosti procesa planiranja i praćenja proizvodnje, kao i sami postupak izbora modela i metode optimizacije fleksibilnog i prilagodljivog procesa i sadržaja planiranja i praćenja proizvodnje u uvjetima neizvjesnosti i promjena. To više što se do sada nije u znanosti posebno istraživao utjecaj samog procesa planiranja i praćenja na uspješnost proizvodnje.

Daljnja istraživanja procesa planiranja i praćenja proizvodnje bila bi zanimljiva i značajna kada bi se obavljala u sljedeća tri pravca:

1. Istraživanje postupaka i modela optimiranja strukture proizvodnog i poslovnog sustava u funkciji fleksibilnosti i prilagodbe u uvjetima neizvjesnosti i promjena kojim bi trebalo odrediti kako struktuirati proizvodni sustav i voditi proizvodni proces kako bi bio optimalno fleksibilan i prilagodljiv prema odabranim kriterijima.

   Tu se posebno misli na čvršće povezivanje procesa planiranja i praćenja proizvodnje s procesima upravljanja poslovnim sustavom i u tom kontekstu veće povezivanje s procesima prodaje, nabave i proizvodnje, a i šire.
2. Moguće varijante i način izbora postupaka za određivanje i razvoj procesa planiranja i praćenja u funkciji upravljanja ne samo proizvodnjom već i poslovnim sustavom, kako je to već započeto u području upravljanja složenim projektima.

   Ovaj pravac daljnjeg istraživanja neposredno je povezan s prethodno navedenim jer je bitno istovremeno optimirati i strukturu i procese proizvodnog sustava ako se želi postizati njegova veća optimalnost, fleksibilnost i prilagodljivost.
3. U daljnjem istraživanju bilo bi značajno utvrditi ulogu procesa planiranja i praćenja proizvodnje u stvaranju osnova za rad na razvoju proizvodnog sustava i ostalih vezanih procesa primjenom Lean pristupa ili nekih drugih metoda i tehnika rada na unapređenju i razvoju, ne samo proizvodnje nego i cijelog poslovnog sustava.

   Naime, ako se proces planiranja i praćenja proizvodnje uključi u proces planiranja i praćenja ukupnog poslovnog sustava i svih njegovih procesa, praćenjem rezultata i izvedenih aktivnosti mogu se na sustavan način prikupiti opsežnije, preciznije i brojnije informacije o mogućnostima razvoja i unapređenja svih procesa i sadržaja rada poslovnog sustava.

U svakom slučaju može se očekivati daljnji interes i potrebe istraživanja procesa planiranja i praćenja proizvodnje u uvjetima neizvjesnosti i promjena te drugim specifičnim uvjetima za razne oblike proizvodnje, a ovo je istraživanje samo jedan korak u tom smjeru.

8. LITERATURA

[1] T.J.Coelli; D.S. Prasada Rao; C.J. O'Donnell; G.E.Battese, *"An Introduction To Efficiency And Productivity Analysis"*, 2. edition, Springer, New York, 2005.

[2] T.E.Vollman; W.L.Berry; D.C.Whybark, *"Manufacturing Planning And Control System"*, 4. edition, McGrow-Hill, 1997.

[3] Tan C. Miller, *"Hierarchical Operations And Supply Chain Planning"*, Springer, New York, 2002.

[4] Michael L. Pinedo, *"Planning And Scheduling In Manufacturing And Services"*, Springer, New York, 2004.

[5] Steven T. Hackman, *"Production Economics"*, Krieger Publishing Co., Melbourne, Florida/US, 2007.

[6] Massimiliano Caramia; Paolo Dell' Olmo *"Effective Resource Management In Manufacturing Systems: Optimization Algorithms For Production Planning"*, Springer, New York, 2006.

[7] Stefan Voss; David L. Woodruff; *"Introduction To Computational Optimization Models For Production Planning In A Supply Chain"*, Springer, New York, 2002.

[8] Robert M. Tork; Patrick J. Cordon; *"Operational Profitability"*, John Wiley&Sons, New York, 2002.

[9] Pierluigi Argonato & Coautors, *"Production Planning In Production Networks: Models For Medium and Short-term Planning"*, Springer, New York, 2008.

[10] Ronald G. Askin; Jeffrey B. Goldberg, *"Design And Analysis Of Lean Production System"*, John Willey& Sons, USA, 2001.

[11] Zdravko Zekić, *"Projektni menadžment – upravljanje razvojnim promjenama"*, Ekonomski fakultet u Rijeci, 2010.

[12] C.A.Soman; D.P.Van Donk; G.J.C.Gaalman, *"Capacitated Planning And Scheduling For Combined Make-to-order And Make-to-stock Production In Food Industry"*, International Journal Of Production Economics, Vol.108, pages 191-199, 2007.

[13] L.C.Hendry; B.G.Kingsman, *"Production Planning System And Their Applicability To Make-to-order Companies"*, European Journal Of Operational Research, Vol.40, pages 1-15, 1989.

[14] G.Zapfel, H.Missbaner, *"New Concepts For Production Planning And Control"*, European Journal Of Operational Research, Vol.67, pages 297-320, 1993.

[15] J.Olhanger; M.Rudberg; J.Vikner, *"Long.term Capacity Management: Linking The Perspectives For Manufacturing Strategy And Sales And Operations Planning"*, International Journal Of Production Economics, Vol.69, pages 215-225, 2001.

[16] N.Štefanić; N.Gjeldim; T.Mikac, *"Primjena Lean koncepta u proizvodnoj djelatnosti"*, Tehnički vjesnik, br.17 (3) stranice 353-356, 2010.

[17] R.Lujić; T.Šarić; G.Šimunović, *"Primjena ekspertnog sustava pri određivanju klase prioriteta radnog naloga u pojedinačnoj proizvodnji"*, Tehnički vjesnik, br.14(1,2), stranice 65-75, 2010.

[18] Martin J. Land; Gerard J. C. Gaalman, *"Production Planning And Control in SMEs: Time For Change"*, Production Planning & Control Journal, 7/2009., pages 548-558

[19] J. Alfaro; A. Ortiz; R. Poler, *"Performance Measurement System For Business Processes"*, Production Planning & Control Journal, 8/2007., pages 641-654

[20] John J. Kanet; Martin Stoesslein, *"Integrating Production Planning And Control: Towards A Simple Model For Capacitated ERP"*, Production Planning & Control Journal, 3/2010, pages 286-300

[21] Philip G. Moscoso; Jan C. Fransoo; Dieter Fisher, *"An Empirical Study on Reducing Planning Instability in Hierarchical Planning System"*, Production Planning & Control Journal, 4/2010, pages 413-426

[22] Gyu C. Kim; Marc J. Schniederjans; Stacy S. Kim, *"Simulation Study of Availability Management in a Make-to-order Manufacturing Environment for a Differentiated Order System"*, Production Planning & Control Journal, 1/2010, pages 47-49

[23] Min Zhen; Tariq Masood; Aysin Rahimifard; Richard Weston, *"A Structural Modelling Aproach to Simulating Dynamic Behaviours in Complex Organization"*, Production Planning & Control Journal, 6/2009, pages 496-509

[24] H. Stefansson; P. Jensson; N. Shah, *"Procedure for Reducing the Risk of Delayed Deliveries in Make-to-order Production"*, Production Planning & Control Journal, 4/2009, pages 332-342

[25] Jorge E. Hernandez; Josefa Mula; Francisco J. Ferriols, *"A Reference Model for Conceptual Modelling of Production Planning Processes"*, Production Planning & Control Journal, 8/2008, pages 725-734

[26] Mohammed M. Al Durgham; Mahmoud A. Barghash, *"A Generalised Framework for Simulation-based Decision Support for Manufacturing"*, Production Planning & Control Journal, 5/2008, pages 518-534

[27] R. Affonso; F. Marcotte; B. Grabot, *"Sales and Operations Planning: the Supply Chain Pillar"*, Production Planning & Control Journal, 2/2008, pages 132-141

[28] Domenico Aprile, A. Claudio Garavelli, Ilaria Giannoccaro, *"Operations Planning and Flexibility in a Supply Chain"*, Production Planning & Control Journal, 1/2005, pages 21-31

[29] Nuran Acur; Umit Bititci, *"Managing Strategy through Business Processes"*, Production Planning & Control Journal, 4/2003, pages 309-326

[30] Tapani Taskinen, *"Improving Change Management Capabilities in Manufacturing: From Theory to Practice"*, Production Planning & Control Journal, 2/2003, pages 201-211

[31] Jatinder N. D. Gupta, *"An Excursion in Scheduling Theory: An Overwiew of Scheduling Research in the Twentieth Century"*, Production Planning & Control Journal, 2/2002, pages 105-116

[32] Siddharth Mestry; Purushothaman Damodaran; Chin-Sheng Chen, *"A Branch and Price Solution Approach for Order Acceptance and Capacity Planning in Make-to-order Operations"*, European Journal Of Operational Research, Vol.211/2011, pages 480-495

[33] Emmett J. Lodree, Jr**,** *"Advanced Supply Chain Planning with Mixtures of Backorders, Lost Sales, and Lost Contract"*, European Journal Of Operational Research, Vol.181/2007, pages 168-183

[34] Guisen Xue; O. Felix Offodile; Hong Zhou; Marvin D. Troutt**,** *"Integrated Production Planning with Sequence-dependent Family Setup Times"*, International Journal Of Production Economics, Vol.131/2011, pages 674-681

[35] Thomas Volling; Thomas S. Spengler**,** *"Modeling and Simulation of Order-driven Planning Policies in Build-to-order Automobile Production"*, International Journal Of Production Economics, Vol.131/2011, pages 183-193

[36] Ely Laureano Paiva**,** *"Manufacturing and Marketing Integration from a Cumulative Capabilities Perspective"*, International Journal Of Production Economics, Vol.126/2010, pages 379-386

[37] J. Mula, R. Poler; J. P. García-Sabater; F.C. Lario**,** *"Models for Production Planning under Uncertainty: A Review"*, International Journal Of Production Economics, Vol.103/2006, pages 271-285

[38] Zdravko Zekić, *"Logistički model dinamičke optimizacije poslovanja poduzeća"*, Ekonomski pregled, Vol. 52/2001

PRILOG

PRILOG 9.1-1. ***Pregled strojeva, opreme i radnika s pripadajućim zastojima i njihovim zakonitostima trajanja***

STROJEVI I OPREMA R.br.	N a z i v	Oznaka	Broj kom.	Godišnji broj zastoja	Ukupan broj zastoja	Učešće zastoja (%)	Kumulativno učešće zastoja (%)	Broj radnika	Vjerojatnost trajanja zastoja u satima 1	2	3	4	8	12	16	24	32	48	64	80
01.	Škare	Š1	1	10	10	2,65	2,65	4	-	0,10	-	0,06	0,17	-	0,31	-	0,24	0,12	-	-
02.	Škare	Š2	2	12	24	6,35	9,00	8	-	0,10	-	0,06	0,17	-	0,31	-	0,24	0,12	-	-
03.	Ekscentar preša	EP1	2	5	10	2,65	11,65	8	-	-	-	0,07	0,12	-	0,08	0,22	0,25	0,10	0,16	-
04.	Ekscentar preša	EP2	1	8	8	2,12	13,77	4	-	-	-	0,07	0,12	-	0,08	0,22	0,25	0,10	0,16	-
05.	Ekscentar preša	EP3	1	10	10	2,65	16,42	4	-	-	-	0,07	0,12	-	0,08	0,22	0,25	0,10	0,16	-
06.	Ekscentar preša	EP4	1	6	6	1,58	18,00	4	-	-	-	0,07	0,12	-	0,08	0,22	0,25	0,10	0,16	-
07.	Hidraulička preša	HP1	1	5	5	1,32	19,32	4	-	-	-	0,05	0,08	-	0,20	0,13	0,19	0,11	0,09	0,15
08.	Hidraulička preša	HP2	1	8	8	2,12	21,44	4	-	-	-	0,05	0,08	-	0,20	0,13	0,19	0,11	0,09	0,15
09.	Hidraulička preša	HP3	2	7	14	3,70	25,14	8	-	-	-	0,05	0,08	-	0,20	0,13	0,19	0,11	0,09	0,15
10.	Aparat za zavar.	AZ1	3	28	84	22,22	47,36	12	0,08	0,15	0,04	0,13	0,20	0,10	0,17	0,10	0,03	-	-	-
11.	Aparat za zavar.	AZ2	1	22	22	5,82	53,18	4	0,08	0,15	0,04	0,13	0,20	0,10	0,17	0,10	0,03	-	-	-
12.	Aparat za zavar.	AZ3	2	19	38	10,05	63,23	8	0,08	0,15	0,04	0,13	0,20	0,10	0,17	0,10	0,03	-	-	-
13.	Aparat za zavar.	AZ4	2	24	48	12,70	75,93	8	0,08	0,15	0,04	0,13	0,20	0,10	0,17	0,10	0,03	-	-	-
14.	Aparat za zavar.	AZ5	1	20	20	5,30	81,23	4	0,08	0,15	0,04	0,13	0,20	0,10	0,17	0,10	0,03	-	-	-
15.	Stroj za obrezivanje	PB1	1	6	6	1,58	82,81	4	0,12	0,19	0,12	0,28	0,15	0,06	0,08	-	-	-	-	-
16.	Naprava za prsten.	NP1	1	4	4	1,06	83,87	4	0,12	0,19	0,12	0,28	0,15	0,06	0,08	-	-	-	-	-
17.	Naprava za prsten.	NP2	1	7	7	1,85	85,72	4	0,12	0,19	0,12	0,28	0,15	0,06	0,08	-	-	-	-	-
18.	Uređaj za bajcanje	UB1	1	8	8	2,12	87,84	4	-	0,12	-	0,15	0,21	0,12	0,17	0,14	0,09	-	-	-
19.	Kotao za emajliranje	KE1	9	0	0	0	87,84	72	-	-	-	-	-	-	-	-	-	-	-	-
20.	Sušara	SU1	2	4	8	2,12	89,96	40	-	-	-	0,10	0,19	0,08	0,27	0,11	0,15	0,07	0,03	-
21.	Peć	PE1	2	6	12	3,17	93,13	40	-	-	-	-	0,07	-	0,15	0,10	0,30	0,20	0,13	0,05
22.	Sredstva unut. transp.	UT1	2	13	26	6,87	100,00	40	0,08	0,14	0,10	0,27	0,18	0,10	0,13	-	-	-	-	-
23.	Mjesto montaže	MM1	-	-	-	-	-	80	0,30	0,23	0,09	0,20	0,16	-	-	-	-	-	-	-
24.	Mjesto pakiranja	MP1	-	-	-	-	-	80	0,30	0,23	0,09	0,20	0,16	-	-	-	-	-	-	-
25.	Pomoćni radnici	POR	-	-	-	-	-	40	0,30	0,23	0,09	0,20	0,16	-	-	-	-	-	-	-

PRILOG 9.1-2. ***Pregled normativa i prosječnog mjesečnog utroška materijala i dijelova po grupama proizvoda***

SIROVINE I DIJELOVI R.br. N a z i v kg,kom.	Proizvodi P1 Jedin. potroš. kom.	Prosječna mjesečna proizvod. kg,kom.	Prosječne mjesečne potrebe kg,kom.	Proizvodi P2 Jedin. potroš. kom.	Prosječna mjesečna proizvod. kg,kom.	Prosječne mjesečne potrebe kg,kom.	Proizvodi P3 Jedin. potroš. kom.	Prosječna mjesečna proizvod. kg,kom.	Prosječne mjesečne potrebe kg,kom.	Proizvodi P4 Jedin. potroš. kom.	Prosječna mjesečna proizvod. kg,kom.	Prosječne mjesečne potrebe kg,kom.	Proizvodi P5 Jedin. potroš. kom.	Prosječna mjesečna proizvod. kg,kom.	Prosječne mjesečne potrebe kg,kom.	Proizvodi P6 Jedin. potroš. kom.	Prosječna mjesečna proizvod. kg,kom.	Prosječne mjesečne potrebe kg, kom.	UKUPNA PROSJ. MJESEČ. POTROŠ.
01. Č. lim, d=1,5 mm	0,24	28500	6840	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	18240
	0,16	28500	4560	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
	0,24	28500	6840	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
02. Č. lim, d=1,2 mm	6,30	14250	89775	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	247950
	4,80	14250	68400	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
	6,30	14250	89775	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
03. Č. lim, d=1,0 mm	-	-	-	5,30	20667	109535	-	-	-	-	-	-	-	-	-	-	-	-	117802
	-	-	.	0,40	20667	8267	-	-	-	-	-	-	-	-	-	-	-	-	
04. Č. lim, d=0,8 mm	-	-	-	-	-	-	0,70	52083	36458	1,25	62583	78229	0,40	15083	6033	-	-	-	131278
	-	-	-	-	-	-	-	-	-	-	-	-	0,70	15083	10558	-	-	-	
05. Č. lim, d=0,6 mm	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	1,20	24750	29700	29700
06. Traka, d=0,3 mm	-	-	-	-	-	-	0,008	52083	417	0,012	62583	751	0,10	15083	151	-	-	-	1319
07. Emajl, TEP1	1,20	14250	17100	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	17100
08. Emajl, TE1	-	-	-	0,50	20667	10334	0,20	52083	10417	0,25	62583	15646	0,25	15083	3771	0,30	24750	7425	47593
09. Emajl PEP2	-	-	-	0,20	20667	4133	-	-	-	-	-	-	-	-	-	-	-	-	4133
10. Emajl PEP3	-	-	-	-	-	-	0,10	52083	5208	0,08	62583	5007	0,10	15083	1508	-	-	-	11723
11. Emajl PEP4	-	-	-	-	-	-	-	-	-	0,08	62583	5007	0,10	15083	1508	0,12	24750	2970	9485
12. Emajl PEP5	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	0,12	24750	2970	2970
13. Most M1	-	-	-	-	-	-	2	52083	104166	2	62583	125166	-	-	-	-	-	-	229332
14. Most M2	-	-	-	-	-	-	-	-	-	-	-	-	1	15083	15083	-	-	-	15083
15. Grlo G1	-	-	-	-	-	-	-	-	-	-	-	-	1	15083	15083	-	-	-	15083
16. Ručka B1	-	-	-	-	-	-	2	52083	104166	2	62583	125166	-	-	-	-	-	-	229332
17. Ručka B2	-	-	-	-	-	-	-	-	-	-	-	-	1	15083	15083	-	-	-	15083
18. Ručka R1	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	2	24750	49500	49500
19. Poklopac PO	-	-	-	-	-	-	-	-	-	-	-	-	1	15083	15083	-	-	-	15083
20. Vijak	-	-	-	-	-	-	2	52083	104166	2	62583	125166	2	15083	30166	-	-	-	259498

PRILOG 9.1-3. Podaci i obilježja plasmana grupe proizvoda P1

Tablica 9.1-3.1. *Prosječne mjesečne narudžbe grupe proizvoda P1 po kupcima (kom.)*

Kupci	I.	II.	III.	IV.	V.	VI.	VII.	VIII.	IX.	X.	XI.	XII.
KP11	5000	5000	5000	4000	3000	3000	4000	4000	6000	5000	4000	4000
KP12	6000	7000	6000	5000	4000	4000	6000	7000	7000	6000	6000	4000
KP13	4000	4000	3000	3000	2000	2000	3000	4000	4000	4000	3000	3000

Tablica 9.1-3.2. *Zakonitost odstupanja veličine redovnih narudžbi za proizvode grupe P1*

	Prosječna odstupanja količina po redovnim narudžbama (%) po razredima						
Učestalost pojave (%) po kupcima	< -12 - 14,3	-12 do -6 - 8,7	-6 do -3 - 4,4	-3 do 3 0	3 do 8 5,2	8 do 14 11,3	> 14 16,8
SVI KUPCI	12,2	5,8	16,3	39,4	4,8	17,5	4,0

Tablica 9.1-3.3. *Broj i rokovi isporuka po kupcima za proizvode grupe P1*

K U P C I	Prosječni mjesečni broj isporuka	Termini u mjesecu i vjerojatnost izbora termina isporuka			
		1. – 5. dan	6. – 10. dan	11. – 15. dan	16. – 20.dan
KP11	2 (jednake)	jednaka (0,10)		-	jednaka (0,20)
KP12	3 (jednake)	jednaka (0,20)	-	jednaka (0,20)	jednaka (0,20)
KP13	1	jednaka (0,10)		-	-

Tablica 9.1-3.4. *Obilježja i vjerojatnosti dopunskih narudžbi za proizvode grupe P1*

a. dopunske narudžbe/mjesec 1 (0,41) 2 (0,31) 3 (0,28)
b. veličina dopunske narudžbe 5-25% od osnovne, za svaku jednaka vjerojatnost
c. kupci s dodatnim narudžbama KP11 (0,35) KP12 (0,40) KP13 (0,25)
d. termini naručivanja dopunskih narudžbi - jednaka vjerojatnost po tjednima

Tablica 9.1-3.5. *Vjerojatnost traženih rokova isporuke za dopunske narudžbe P1*

Traženi rokovi isporuka dopunskih narudžbi proizvoda grupe P1(radni dani)	5	6	7	8	9	10
Vjerojatnost	0,20	0,10	0,34	0,13	0,12	0,11

PRILOG 9.1-4. Podaci i obilježja plasmana grupe proizvoda P2

Tablica 9.1-4.1. *Prosječne mjesečne narudžbe grupe proizvoda P2 po kupcima (kom.)*

Kupci	I.	II.	III.	IV.	V.	VI.	VII.	VIII.	IX.	X.	XI.	XII.
KP2$_1$	13000	16000	15000	14000	14000	11000	11000	13000	16000	17000	15000	12000
KP2$_2$	7000	8000	7000	6000	6000	5000	5000	7000	8000	9000	7000	6000

Tablica 9.1-4.2. *Zakonitost odstupanja veličine redovnih narudžbi za proizvode grupe P2*

	Prosječna odstupanja količina po redovnim narudžbama (%) po razredima						
Učestalost pojave	< -12	-12 do -6	-6 do -3	-3 do 3	3 do 6	6 do 12	> 12
(%) po kupcima	- 13,5	- 8,7	- 4,0	0	4,3	9,4	14,7
SVI KUPCI	11,8	7,9	10,7	29,3	11,1	13,9	15,3

Tablica 9.1-4.3. *Broj i rokovi isporuka po kupcima za proizvode grupe P2*

K U P C I	Prosječni mjesečni broj isporuka	Termini u mjesecu i vjerojatnost izbora termina isporuka			
		1. – 5. dan	6. – 10. dan	11. – 15. dan	16. – 20. dan
KP1$_1$	2 (jednake)	jednaka (0,10)		jednaka (0,10)	
KP1$_3$	1		jednaka (0,10)		

Tablica 9.1-4.4. *Obilježja i vjerojatnosti dopunskih narudžbi za proizvode grupe P2*

a. dopunske narudžbe/mjesec 1 (0,44) 2 (0,27) 3 (0,29)
b. veličina dopunske narudžbe 5-20% od osnovne, za svaku jednaka vjerojatnost
c. kupci s dodatnim narudžbama KP2$_1$ (0,63) KP2$_3$ (0,37)
d. termini naručivanja dopunskih narudžbi -jednaka vjerojatnost po tjednima

Tablica 9.1-4.5. *Vjerojatnost traženih rokova isporuke za dopunske narudžbe P2*

Traženi rokovi isporuka dopunskih narudžbi proizvoda grupe P2 (radni dani)	5	6	7	8	9	10
Vjerojatnost	0,26	0,12	0,21	0,07	0,10	0,24

PRILOG 9.1-5. Podaci i obilježja plasmana grupe proizvoda P3

Tablica 9.1-5.1. *Prosječne redovne mjesečne narudžbe grupe proizvoda P3 po kupcima (kom.)*

Kupci	I.	II.	III.	IV.	V.	VI.	VII.	VIII.	IX.	X.	XI.	XII.
KP3$_1$	6000	7200	8000	7000	6000	5800	6000	7200	8200	8000	7000	6000
KP3$_2$	6000	7000	8000	7200	5800	6000	6000	7000	7800	8000	7200	6000
KP3$_3$	5000	5800	6200	5600	5000	4800	4800	5600	6200	6200	5800	5000
KP3$_4$	4000	4600	5400	4800	4200	4200	4000	4800	5400	5400	4800	4000
KP3$_5$	4000	4600	5200	4600	3800	4000	4000	4600	5200	5200	4600	4000
KP3$_6$	5000	5400	6200	5200	5200	5000	5000	5400	6200	6200	5400	5000

Tablica 9.1-5.2. *Prosječne dodatne mjesečne narudžbe grupe proizvoda P3 po kupcima (kom.)*

Kupci	I.	II.	III.	IV.	V.	VI.	VII.	VIII.	IX.	X.	XI.	XII.
KP3$_7$	0	7200	8000	7000	0	5800	0	7200	8200	8000	7000	6000
KP3$_8$	0	7000	8000	7200	5800	0	6000	0	7800	8000	0	6000
KP3$_9$	5000	5800	6200	5600	0	0	4800	5600	6200	6200	5800	0
KP3$_{10}$	4000	4600	5400	0	4200	0	4000	0	5400	5400	4800	0
KP3$_{11}$	4000	4600	5200	0	3800	4000	0	4600	5200	5200	4600	4000
KP3$_{12}$	5000	5400	6200	5200	0	5000	0	5400	6200	6200	0	5000

Tablica 9.1-5.3. *Zakonitost odstupanja veličine narudžbi za proizvode grupe P3*

	Prosječna odstupanja količina po redovnim narudžbama (%) po razredima						
Učestalost pojave (%) po kupcima	< -12 - 13,0	-12 do -6 - 9,1	-6 do -3 - 4,3	-3 do 3 0	3 do 6 4,8	6 do 12 9,2	> 12 14,4
SVI KUPCI	12,6	7,1	10,2	29,8	10,1	14,4	15,8

Tablica 9.1-5.4. *Broj i vjerojatnost dopunskih narudžbi redovnih kupaca za grupu proizvoda P3*

Ukupan broj dopunskih narudžbi u jednom mjesecu	4	5	6	7	8	9	10	11	12
Vjerojatnost	0,07	0,05	0,14	0,12	0,20	0,18	0,17	0,03	0,04

Tablica 9.1-5.5. *Vjerojatnost pojave redovnih kupaca s dopunskim narudžbama za proizvode P3*

K U P C I	KP3$_1$	KP3$_2$	KP3$_3$	KP3$_4$	KP3$_5$	KP3$_6$
Vjerojatnost	0,22	0,16	0,14	0,11	0,11	0,26

Tablica 9.1-5.6. *Obilježja i vjerojatnosti dopunskih narudžbi za proizvode grupe P3*

a. veličina dopunske narudžbe 5-20% od osnovne, za svaku jednaka vjerojatnost
b. termini naručivanja dopunskih narudžbi jednaka vjerojatnost po tjednima

Tablica 9.1-5.7. *Vjerojatnost traženih rokova isporuke za dopunske narudžbe P3*

Traženi rokovi isporuka dopunskih narudžbi proizvoda grupe P3 (radni dani)	2	3	4	5	6	7	8
Vjerojatnost	0,06	0,08	0,17	0,23	0,11	0,25	0,10

PRILOG 9.1-6. Podaci i obilježja plasmana grupe proizvoda P4

Tablica 9.1-6.1. *Prosječne redovne mjesečne narudžbe grupe proizvoda P4 po kupcima (kom.)*

Kupci	I.	II.	III.	IV.	V.	VI.	VII.	VIII.	IX.	X.	XI.	XII.
KP41	12000	12000	13000	12000	11000	11000	11000	12000	13000	12000	12000	11000
KP42	8000	9000	10000	9000	8000	7000	6000	8000	9000	9000	8000	7000
KP43	6000	7000	7000	7000	6000	5000	5000	6000	6000	7000	6000	6000
KP44	5000	6000	8000	7000	6000	5000	5000	5000	6000	6000	5000	4000
KP45	5000	6000	6000	5000	5000	4000	4000	5000	6000	6000	5000	4000
KP46	4000	5000	6000	5000	4000	3000	4000	4000	5000	5000	4000	3000

Tablica 9.1-6.2. *Prosječne dodatne mjesečne narudžbe grupe proizvoda P4 po kupcima (kom.)*

Kupci	I.	II.	III.	IV.	V.	VI.	VII.	VIII.	IX.	X.	XI.	XII.
KP47	7000	8000	7000	5000	5000	3000	3000	6000	6000	8000	8000	6000
KP48	5000	6000	4000	4000	5000	0	3000	0	3000	6000	6000	0
KP49	0	5000	3000	6000	0	3000	0	4000	3000	4000	0	6000
KP410	5000	3000	3000	0	4000	0	2000	0	4000	4000	5000	3000
KP411	0	4000	3000	3000	0	2000	0	4000	3000	3000	0	5000
KP412	0	3000	2000	2000	2000	2000	2000	2000	3000	3000	3000	5000
KP413	3000	2000	3000	0	4000	0	0	4000	3000	2000	3000	0

Tablica 9.1-6.3. *Zakonitost odstupanja veličine narudžbi za proizvode grupe P4*

	Prosječna odstupanja količina po redovnim narudžbama (%) po razredima						
Učestalost pojave (%) po kupcima	< -13 - 15,1	-13 do -7 - 10,2	-7 do -3 - 5,6	-3 do 3 0	3 do 7 4,9	7 do 15 11,00	> 15 16,7
SVI KUPCI	6,5	15,6	10,2	26,3	16,5	13,2	11,7

Tablica 9.1-6.4. *Broj i vjerojatnost dopunskih narudžbi redovnih kupaca za grupu proizvoda P4*

Ukupan broj dopunskih narudžbi u jednom mjesecu	5	6	7	8	9	10	11	12
Vjerojatnost	0,03	0,10	0,08	0,14	0,10	0,18	0,17	0,10

Tablica 4.2-4.5. *Vjerojatnost pojave redovnih kupaca s dopunskim narudžbama za proizvode P4*

K U P C I	$KP4_1$	$KP4_2$	$KP4_3$	$KP4_4$	$KP4_5$	$KP4_6$
Vjerojatnost	0,12	0,07	0,20	0,18	0,14	0,29

Tablica 9.1-6.6. *Obilježja i vjerojatnosti dopunskih narudžbi za proizvode grupe P4*

a. veličina dopunske narudžbe 5-20% od osnovne, za svaku jednaka vjerojatnost
b. termini naručivanja dopunskih narudžbi - jednaka vjerojatnost po tjednima

Tablica 9.1-6.7. *Vjerojatnost traženih rokova isporuke za dopunske narudžbe P4*

Traženi rokovi isporuka dopunskih narudžbi proizvoda grupe P4 (radni dani)	2	3	4	5	6	7	8
Vjerojatnost	0,09	0,05	0,14	0,29	0,12	0,20	0,11

PRILOG 9.1-7. Podaci i obilježja plasmana grupe proizvoda P5

Tablica 9.1-7.1. *Prosječne redovne mjesečne narudžbe grupe proizvoda P5 po kupcima (kom.)*

Kupci	I.	II.	III.	IV.	V.	VI.	VII.	VIII.	IX.	X.	XI.	XII.
KP5$_1$	4000	4000	3000	3000	3000	3000	3000	3000	3000	4000	4000	4000
KP5$_2$	4000	4000	3000	3000	3000	3000	3000	2000	3000	4000	3000	4000
KP5$_3$	2000	2000	2000	2000	2000	1000	1000	1000	2000	2000	2000	2000

Tablica 9.1-7.2. *Prosječne dodatne mjesečne narudžbe grupe proizvoda P5 po kupcima (kom.)*

Kupci	I.	II.	III.	IV.	V.	VI.	VII.	VIII.	IX.	X.	XI.	XII.
KP5$_4$	2000	2000	2000	2000	2000	1600	1200	1200	1600	2400	2000	2000
KP5$_5$	2000	1600	2400	1200	0	1200	1600	0	1200	1600	2000	1600
KP5$_6$	1600	1200	0	2000	0	1200	0	800	1200	1200	1400	1600
KP5$_7$	1400	1200	1600	0	2000	0	1200	0	1200	1200	1200	1200
KP5$_8$	1200	1200	1200	800	1200	0	0	1200	800	800	800	800
KP5$_9$	800	800	800	0	800	0	0	800	0	800	600	800

Tablica 9.1-7.3. *Zakonitost odstupanja veličine narudžbi za proizvode grupe P5*

	Prosječna odstupanja količina po redovnim narudžbama (%) po razredima						
Učestalost pojave (%) po kupcima	< -12 - 13,3	-12 do -8 - 9,8	-8 do -3 - 5,7	-3 do 3 0	3 do 8 5,5	8 do 16 11,2	> 16 17,3
SVI KUPCI	14,1	20,0	13,7	8,9	15,8	15,1	12,4

Tablica 9.1-7.4. *Obilježja i vjerojatnosti dopunskih narudžbi za proizvode grupe P5*

a. dopunske narudžbe/mjesec 2 (0,12) 3 (0,22) 4 (0,37) 5 (0,29)
b. veličina dopunske narudžbe 5-20% od osnovne, za svaku jednaka vjerojatnost
c. kupci s dodatnim narudžbama KP5$_1$ (0,36) KP5$_2$ (0,41) KP2$_3$ (0,37)
d. termini naručivanja dopunskih narudžbi - jednaka vjerojatnost po tjednima

Tablica 9.1-7.5. *Vjerojatnost traženih rokova isporuke za dopunske narudžbe P5*

Traženi rokovi isporuka dopunskih narudžbi proizvoda grupe P5 (radni dani)	3	4	5	6	7	8	9	10
Vjerojatnost	0,14	0,09	0,21	0,13	0,19	0,14	0,05	0,05

PRILOG 9.1-8. Podaci i obilježja plasmana grupe proizvoda P6

Tablica 9.1-8.1. *Prosječne redovne mjesečne narudžbe grupe proizvoda P6 po kupcima (kom.)*

Kupci	I.	II.	III.	IV.	V.	VI.	VII.	VIII.	IX.	X.	XI.	XII.
KP61	3000	4000	4000	3000	3000	2000	2200	3000	4000	4000	3000	3000
KP62	2400	3000	3000	2600	2600	2000	1800	2400	3000	3000	2600	2400
KP63	2000	2400	2400	2000	2000	1400	1400	2000	2400	2600	2000	2000
KP64	1600	2000	2000	1400	1400	1000	1000	1600	2000	2000	1400	1600
KP65	1000	1600	1600	1000	1000	600	600	1000	1600	1400	1000	1000

Tablica 9.1-8.2. *Prosječne dodatne mjesečne narudžbe grupe proizvoda P6 po kupcima (kom.)*

Kupci	I.	II.	III.	IV.	V.	VI.	VII.	VIII.	IX.	X.	XI.	XII.
KP66	3000	4000	3200	3200	3000	3000	0	4000	4000	4000	3000	3000
KP67	2400	3000	2800	2400	2400	0	3000	3000	0	4000	3000	4000
KP68	2000	2000	1600	2400	0	3000	0	3000	4000	2000	4000	0
KP69	2000	2600	1600	0	2400	0	3000	0	3000	2000	2000	3000
KP610	1600	2000	1600	2400	1200	2000	2000	0	2000	2000	3000	0
KP611	1000	1400	1200	1600	0	1000	1000	2000	2000	1000	0	1000

Tablica 9.1-8.3. *Zakonitost odstupanja veličine narudžbi za proizvode grupe P6*

	Prosječna odstupanja količina po redovnim narudžbama (%) po razredima						
Učestalost pojave (%) po kupcima	< -12 - 13,8	-12 do -7 - 9,7	-7 do -3 - 4,8	-3 do 3 0	3 do 8 5,3	8 do 14 19,1	> 14 10,6
SVI KUPCI	5,6	8,9	16,3	28,3	11,2	19,1	10,6

Tablica 9.1-8.4. *Broj i vjerojatnost dopunskih narudžbi redovnih kupaca za grupu proizvoda P6*

Ukupan broj dopunskih narudžbi u jednom mjesecu	4	5	6	7	8	9	10
Vjerojatnost	0,12	0,14	0,09	0,18	0,19	0,10	0,08

Tablica 9.1-8.5. *Vjerojatnost pojave redovnih kupaca sa dopunskim narudžbama za proizvode P6*

K U P C I	KP61	KP62	KP63	KP64	KP65
Vjerojatnost	0,15	0,20	0,23	0,27	0,15

Tablica 9.1-8.6. *Obilježja i vjerojatnosti dopunskih narudžbi za proizvode grupe P6*

a. veličina dopunske narudžbe 5-20% od osnovne, za svaku jednaka vjerojatnost
b. termini naručivanja dopunskih narudžbi - jednaka vjerojatnost po tjednima

Tablica 9.1-8.7. *Vjerojatnost traženih rokova isporuke za dopunske narudžbe P6*

Traženi rokovi isporuka dopunskih narudžbi proizvoda grupe P4 (radni dani)	3	4	5	6	7	8
Vjerojatnost	0,13	0,17	0,22	0,16	0,10	0,22

PRILOG 9.1-9. ***Pregled prosječnih zaliha, dobavljača repromaterijala i zakonitosti u nabavi***

SIROVINE I DIJELOVI R.br. N a z i v	Šifra	Maksimalne zalihe (kg, kom) **ZS_{max}**	Signalne zalihe (kg, kom) **$ZS_{sig.}$**	Količine za naručivanje (kg, kom) **QSN**	MOGUĆI DOBAVLJAČI	Oznake zakonitosti mogućnosti dobivanja potrebnih količina u nabavi
01. Čelični lim, d=1,5 mm	S1	25.000	10.000	15.000	$SD1_{1}$, $SD1_{2}$, $SD1_{3}$, $SD1_{4}$	MK1, MK2, MK3, MK3
02. Čelični lim, d=1,2 mm	S2	350.000	140.000	210.000	$SD2_{3}$, $SD2_{4}$, $SD2_{5}$, $SD2_{6}$, $SD2_{7}$	MK4, MK5, MK6, MK8, MK9
03. Čelični lim, d=1,0 mm	S3	170.000	70.000	105.000	$SD3_{5}$, $SD3_{6}$, $SD3_{7}$, $SD3_{8}$, $SD3_{9}$, $SD3_{10}$	MK7, MK4, MK10, MK6, MK5, MK4
04. Čelični lim, d=0,8 mm	S4	200.000	80.000	120.000	$SD4_{5}$, $SD4_{6}$, $SD4_{7}$, $SD4_{8}$, $SD4_{9}$, $SD4_{10}$	MK7, MK4, MK7, MK6, MK5, MK4
05. Čelični lim, d=0,6 mm	S5	40.000	16.000	24.000	$SD5_{5}$, $SD5_{6}$, $SD5_{7}$, $SD5_{8}$, $SD5_{9}$, $SD5_{10}$	MK1, MK3, MK2, MK7, MK3, MK14
06. Traka, d=0,3 mm	S6	1.850	750	1.100	$SD6_{21}$, $SD6_{22}$, $SD6_{12}$, $SD6_{13}$	MK11, MK11, MK12, MK13
07. Emajl, TEP1	S7	25.000	10.000	15.000	$SD7_{15}$, $SD7_{16}$	MK3, MK2
08. Emajl, TE1	S8	80.000	32.000	48.000	$SD8_{15}$, $SD8_{16}$	MK14, MK19
09. Emajl PEP2	S9	6.000	2.400	3.600	$SD9_{15}$, $SD9_{16}$	MK15, MK17
10. Emajl PEP3	S10	20.000	8.000	12.000	$SD10_{15}$, $SD10_{16}$	MK16, MK1
11. Emajl PEP4	S11	15.000	6.000	9.000	$SD11_{15}$, $SD11_{16}$	MK17, MK20
12. Emajl PEP5	S12	4.000	1.600	2.400	$SD12_{15}$, $SD12_{16}$	MK12, MK15
13. Most M1	S13	370.000	150.000	220.000	$SD13_{11}$, $SD13_{12}$	MK18, MK6
14. Most M2	S14	40.000	16.000	24.000	$SD14_{11}$, $SD14_{12}$	MK3, MK1
15. Grlo G1	S15	40.000	16.000	24.000	$SD15_{11}$, $SD15_{12}$	MK3, MK1
16. Ručka B1	S16	370.000	150.000	220.000	$SD16_{17}$, $SD16_{18}$	MK8, MK6
17. Ručka B2	S17	40.000	16.000	24.000	$SD17_{17}$, $SD17_{18}$	MK3, MK20
18. Ručka R1	S18	66.000	26.000	40.000	$SD18_{13}$, $SD18_{14}$	MK14, MK19
19. Poklopac PO	S19	40.000	16.000	24.000	$SD19_{19}$, $SD19_{20}$	MK3, MK1
20. Vijak	S20	450.000	180.000	270.000	$SD20_{23}$, $SD20_{24}$, $SD20_{25}$, $SD20_{26}$	MK9, MK6, MK8, MK9

PRILOG 9.1-10. Mogućnosti nabave repromaterijala s odgovarajućim vjerojatnostima

Oznaka varijante	Grupe mogućih količina za nabavu repromaterijala (kg, kom) I.	II.	III.	IV.	V.
MK1	0	5.000	10.000	15.000	20.000
MK2	0	15.000	25.000	35.000	45.000
MK3	0	10.000	20.000	25.000	30.000
MK4	0	50.000	100.000	150.000	200.000
MK5	0	100.000	150.000	200.000	250.000
MK6	0	150.000	250.000	350.000	450.000
MK7	0	30.000	60.000	90.000	120.000
MK8	0	200.000	250.000	350.000	400.000
MK9	0	200.000	300.000	400.000	500.000
MK10	0	40.000	80.000	120.000	160.000
MK11	0	400	600	800	1.200
MK12	0	1.000	1.500	2.000	2.500
MK13	0	800	1.200	1.600	2.000
MK14	0	20.000	30.000	40.000	50.000
MK15	0	2.000	3.000	4.000	5.000
MK16	0	3.000	6.000	9.000	12.000
MK17	0	2.000	5.000	8.000	10.000
MK18	0	100.000	200.000	300.000	400.000
MK19	0	20.000	50.000	80.000	100.000
MK20	0	6.000	9.000	12.000	15.000
Vjerojatnost pojave grupe količina za nabavu	0,125	0,250	0,250	0,250	0,125

PRILOG 9.2.-1 Program za ispitivanje modela korektivnog optimiranja

- primjer proizvodnje autostakla

```
function testiranje_modela_optimizacije_4a(varargin)

clear all
clc

% Tablica 1. Ulazni podaci za optimizaciju simplex metodom %


ZK=[0.00028 0.0003 0.00035 0.00028 0.00024 0.0003 0.00027 0.00024 0.0002 0.00023];

PS=[0.11 0.12 0.10 0.09 0.08 0.10 0.09 0.07 0.07 0.08];

Qd=[85 102 122 142 159 183 191 202 218 221
    91 113 132 148 169 196 198 215 224 236
    102 116 138 149 178 204 217 222 235 234
    103 121 147 155 188 216 227 229 241 253
    102 116 136 154 179 211 212 224 233 248
    91 112 129 149 167 193 198 212 224 233];

Qg=[104 124 151 178 188 225 229 249 251 265
    114 138 161 187 211 234 245 268 278 279
    124 138 175 189 225 244 265 275 278 282
    128 149 184 197 224 268 272 276 288 289
    123 144 174 198 215 259 267 266 278 284
    118 136 162 176 199 232 237 258 269 274];

Qp=[95 112 137 155 173 198 205 217 232 244
    102 121 146 165 186 213 221 234 248 262
    107 127 154 166 197 228 235 241 252 265
    111 135 165 178 209 241 248 257 267 276
    106 130 155 167 199 230 237 244 254 267
    101 121 144 163 184 211 218 231 245 257];


for i=1:6
for j=1:10
Qd(i,j)=Qd(i,j)-(Qd(i,j)*X/100);
Qg(i,j)=Qg(i,j)+(Qg(i,j)*X/100);
end
end
display(Qd)
display(Qg)

OK=[0.48 0.51 0.53 0.57 0.54 0.50];


% Model A(Simplex)-----------------------------------------

A=[0.00028 0.0003 0.00035 0.00028 0.00024 0.0003 0.00027 0.00024 0.0002 0.00023];

C=[-501 -568 -428 -364 -302 -358 -311 -225 -218 -238];

for i=1:6
B=OK(i);
lb=Qd(i,:);
ub=Qg(i,:);

    %***Poziv funkcije SIMPLEX metode i ispis rjesenja
    [X,fval]=simplex_metoda(C,A,B,lb,ub);
    display(X);

x(i,:)=X;
```

```
end
fprintf('Plan proizvodnje A:\n');
display(x);
assignin('base', 'x', x);


% Model C-----------------------------------------
% Zakonitost pojave količina u dodatnim narudžbama %

for i=1:6
    for j=1:10
       r1(i,j)=randi([1,100]);
    end
end
for i=1:6
for j=1:3
if r1(i,j)<21
Qdod(i,j)=Qp(i,j)*0.24;
elseif r1(i,j)>20 & r1(i,j)<71
Qdod(i,j)=Qp(i,j)*0.28;
else
Qdod(i,j)=Qp(i,j)*0.36;
end
end
end

for i=1:6
for j=4:6
if r1(i,j)<21
Qdod(i,j)=Qp(i,j)*0.28;
elseif r1(i,j)>20 & r1(i,j)<71
Qdod(i,j)=Qp(i,j)*0.36;
else
Qdod(i,j)=Qp(i,j)*0.40;
end
end
end

for i=1:6
for j=7:10
if r1(i,j)<21
Qdod(i,j)=Qp(i,j)*0.24;
elseif r1(i,j)>20 & r1(i,j)<71
Qdod(i,j)=Qp(i,j)*0.28;
else
Qdod(i,j)=Qp(i,j)*0.36;
end
end
end

fprintf('Dodatne narudžbe:\n');
display(Qdod);
assignin('base', 'Qdod', Qdod);
fprintf('Nasumični brojevi 1:\n');
display(r1);


% Zakonitost pojave količina u izvanrednim narudžbama %


for i=1:6

    r2(i)=randi([1,100]);

    if r2(i)<21
    bp(i)=6;
    end
    if r2(i)>20 & r2(i)<41
```

```
    bp(i)=7;
    end
    if r2(i)>40 & r2(i)<61
    bp(i)=8;
    end
    if r2(i)>60 & r2(i)<81
    bp(i)=9;
    end
    if r2(i)>80
    bp(i)=10;
    end


    for j=1:bp(i)
    r3(j)=randi([1,100]);
    end

maxbp=max(bp);

% Za koji proizvod imamo izvanredne narudžbe %
display(r3);
    for z=1:10
        if z>maxbp
        proi(i,z)=0;
        else
        if r3(z)<11
        Qvan1(i,z)=Qp(i,1);
        proi(i,z)=1;
        end
        if r3(z)>10 & r3(z)<21
        Qvan1(i,z)=Qp(i,2);
        proi(i,z)=2;
        end
        if r3(z)>20 & r3(z)<31
        Qvan1(i,z)=Qp(i,3);
        proi(i,z)=3;
        end
        if r3(z)>30 & r3(z)<41
        Qvan1(i,z)=Qp(i,4);
        proi(i,z)=4;
        end
        if r3(z)>40 & r3(z)<51
        Qvan1(i,z)=Qp(i,5);
        proi(i,z)=5;
        end
        if r3(z)>50 & r3(z)<61
        Qvan1(i,z)=Qp(i,6);
        proi(i,z)=6;
        end
        if r3(z)>60 & r3(z)<71
        Qvan1(i,z)=Qp(i,7);
        proi(i,z)=7;
        end
        if r3(z)>70 & r3(z)<81
        Qvan1(i,z)=Qp(i,8);
        proi(i,z)=8;
        end
        if r3(z)>80 & r3(z)<91
        Qvan1(i,z)=Qp(i,9);
        proi(i,z)=9;
        end
        if r3(z)>90
        Qvan1(i,z)=Qp(i,10);
        proi(i,z)=10;
        end
        end
    end
end
```

```
for i=1:6
    for j=1:10
       r4(i,j)=randi([1,100]);
    end
end

display(r4);
display(bp);
display(proi);
assignin('base', 'proi', proi);

% Zakonitost pojave količina u izvanrednim narudžbama

for i=1:6
for j=1:10
    if j>maxbp
    Qvan(i,j)=0;
    else
    if r4(i,j)<21
    Qvan(i,j)=Qvan1(i,j)*0.24;
    end
    if r4(i,j)>20 & r4(i,j)<41
    Qvan(i,j)=Qvan1(i,j)*0.28;
    end
    if r4(i,j)>40 & r4(i,j)<61
    Qvan(i,j)=Qvan1(i,j)*0.32;
    end
    if r4(i,j)>60 & r4(i,j)<81
    Qvan(i,j)=Qvan1(i,j)*0.36;
    end
    if r4(i,j)>80
    Qvan(i,j)=Qvan1(i,j)*0.4;
    end
    end
end
end

Qvan=round(Qvan);



fprintf('Nasumični brojevi 4:\n');
display(r4);
fprintf('Izvanredne narudžbe:\n');
display(Qvan);
assignin('base', 'Qvan', Qvan);

% Dopunske narudžbe%

for i=1:6
for j=1:10
    if proi(i,j)==0
    Qdop(i,j)=0;
    else
    Qdop(i,j)=Qvan(i,j)+ Qdod(i,proi(i,j));
    end
end
end

fprintf('Dopunske narudžbe:\n');
display(Qdop)

display(proi);

Qpl=x;

for i=1:6
for j=1:10
```

```
   if proi(i,j)==0;
   else
   if x(i,proi(i,j))==Qg(i,proi(i,j))
   Qpl(i,proi(i,j))=Qg(i,proi(i,j));
   Qdop(i,j)=0;
   else
   end
   end
end
end

fprintf('Dopunske narudžbe:\n');
display(Qdop);

assignin('base', 'Qdop', Qdop);

for i=1:6
for j=1:10
if proi(i,j)==0;
else
Qpl(i,proi(i,j))=Qpl(i,proi(i,j))+Qdop(i,j);
if Qpl(i,proi(i,j))>Qg(i,proi(i,j));
Qpl(i,proi(i,j))=Qg(i,proi(i,j));
end
end
end
end

% Pokazatelj Kp za model C%
for i=1:6
    for j=1:10
    Kp(i,j)=ZK(j)/PS(j);
    end
end


for i=1:6
    for j=1:10
    if proi(i,j)==0;
    else
    Kp(i,proi(i,j))=0;
    end
    end
end
fprintf('Pokazatelj Kp za model C:\n');
display(Kp);

% Pokazatelj Ks za model C%
for i=1:6
    for j=1:10
    Ks(i,j)=0;
    end
end
for i=1:6
    for j=1:10
    if proi(i,j)==0;
    else
    Ks(i,proi(i,j))=ZK(j)*PS(j);
    end
    end
end

fprintf('Pokazatelj Ks za model C:\n');
display(Ks);

[Kps,pozKps]=sort(Kp,2,'descend');
[Kss,pozKss]=sort(Ks,2,'descend');
fprintf('Sortirane vrijednosti koeficijenta Kp za model C:\n');
```

```
display(Kps)
fprintf('Proizvodi poredani po vrijednosti koeficijenta Kp za model C:\n');
display(pozKps)
fprintf('Sortirane vrijednosti koeficijenta Ks za model C:\n');
display(Kss)
fprintf('Proizvodi poredani po vrijednosti koeficijenta Ks za model C:\n');
display(pozKss)

for i=1:6
for j=1:10
Qkor(i,pozKss(i,j))=Qpl(i,pozKss(i,j))-x(i,pozKss(i,j));
KK(i,pozKss(i,j))=Qkor(i,pozKss(i,j))*ZK(pozKss(i,j));
end
end
display(Qkor);

fprintf('Korekcija kapaciteta za model C:\n');
display(KK)

for i=1:6
for j=1:10
if x(i,pozKps(i,j))==Qd(i,pozKps(i,j))
KKI(i,pozKps(i,j))=0;
else
KKI(i,pozKps(i,j))=KK(i,pozKss(i,j))/ZK(pozKps(i,j));
end
end
end
fprintf('Količinska korekcija kapaciteta za model C:\n');
display(KKI)


for i=1:6
for j=1:10
Qpl(i,j)=Qpl(i,j)-KKI(i,j);
if Qpl(i,j)<Qd(i,j)
Qpl(i,j)=Qd(i,j);
end
end
end

fprintf('Proizvodni plan za model C:\n');
display(Qpl);
assignin('base', 'Qpl', Qpl);
% ---------------------------------------------------------------------------------
% Model B-------------------------------------------------

for i=1:6
for j=1:10
Qd(i,j)=Qd(i,j)+Qdod(i,j)/4;
Qg(i,j)=Qg(i,j)-Qdod(i,j)/4;
if Qg(i,j)<Qd(i,j)
Qg(i,j)=Qd(i,j);
end
end
end
fprintf('Korigirane donje granice količina za model B i D:\n');
display(Qd);

fprintf('Korigirane gornje granice količina za model B i D:\n');
display(Qg);

A=[0.00028 0.0003 0.00035 0.00028 0.00024 0.0003 0.00027 0.00024 0.0002 0.00023];

C=[-501 -568 -428 -364 -302 -358 -311 -225 -218 -238];
```

```
for i=1:6
B=OK(i);
lb=Qd(i,:);
ub=Qg(i,:);

    %***Poziv funkcije SIMPLEX metode i ispis rjesenja
    [X,fval]=simplex_metoda(C,A,B,lb,ub);
    display(X);

x1(i,:)=X;
end
fprintf('Proizvodni plan za model B:\n');
display(x1);
assignin('base', 'x1', x1);

% Model D-----------------------------------

display(proi);

Qpl1=x1;

for i=1:6
for j=1:10
   if proi(i,j)==0;
   else
   if x1(i,proi(i,j))==Qg(i,proi(i,j))
   Qpl1(i,proi(i,j))=Qg(i,proi(i,j));
   Qvan(i,j)=0;
   else
   end
   end
end
end

fprintf('Izvanredne narudžbe:\n');
display(Qvan);

for i=1:6
for j=1:10
if proi(i,j)==0;
else
Qpl1(i,proi(i,j))=Qpl1(i,proi(i,j))+Qvan(i,j);
if Qpl1(i,proi(i,j))>Qg(i,proi(i,j));
Qpl1(i,proi(i,j))=Qg(i,proi(i,j));
end
end
end
end

% Pokazatelj Kp za model D%
for i=1:6
    for j=1:10
    Kp(i,j)=ZK(j)/PS(j);
    end
end


for i=1:6
    for j=1:10
    if proi(i,j)==0;
    else
    Kp(i,proi(i,j))=0;
    end
    end
end
fprintf('Pokazatelj Kp za model D:\n');
display(Kp);
```

```
% Pokazatelj Ks za model C%
for i=1:6
    for j=1:10
    Ks(i,j)=0;
    end
end
for i=1:6
    for j=1:10
    if proi(i,j)==0;
    else
    Ks(i,proi(i,j))=ZK(j)*PS(j);
    end
    end
end

fprintf('Pokazatelj Ks za model D:\n');
display(Ks);

[Kps,pozKps]=sort(Kp,2,'descend');
[Kss,pozKss]=sort(Ks,2,'descend');
fprintf('Sortirane vrijednosti koeficijenta Kp za model D:\n');
display(Kps)
fprintf('Proizvodi poredani po vrijednosti koeficijenta Kp za model D:\n');
display(pozKps)
fprintf('Sortirane vrijednosti koeficijenta Ks za model D:\n');
display(Kss)
fprintf('Proizvodi poredani po vrijednosti koeficijenta Ks za model D:\n');
display(pozKss)

for i=1:6
for j=1:10
Qkor1(i,pozKss(i,j))=Qpl1(i,pozKss(i,j))-x1(i,pozKss(i,j));
KK(i,pozKss(i,j))=Qkor1(i,pozKss(i,j))*ZK(pozKss(i,j));
end
end
display(Qkor1);

fprintf('Korekcija kapaciteta za model D:\n');
display(KK)

for i=1:6
for j=1:10
if x1(i,pozKps(i,j))==Qd(i,pozKps(i,j))
else
KKI(i,pozKps(i,j))=KK(i,pozKss(i,j))/ZK(pozKps(i,j));
end
end
end
fprintf('Količinska korekcija kapaciteta za model D:\n');
display(KKI)


for i=1:6
for j=1:10
Qpl1(i,j)=Qpl1(i,j)-KKI(i,j);
if Qpl1(i,j)<Qd(i,j)
Qpl1(i,j)=Qd(i,j);
end
end
end

fprintf('Proizvodni plan za model D:\n');
display(Qpl);
assignin('base', 'Qpl1', Qpl1);

% ----------------------------------------

% Prosjecna odstupanja za Model A
```

```
for i=1:10
Qpls_A=sum(x)/10;
end
SQ_A=sum(Qpls_A);

fprintf('Srednje vrijednosti realizacije proizvoda za model A:\n');
display(Qpls_A)
fprintf('Suma srednjih vrijednosti realizacije proizvoda za model A:\n');
display(SQ_A)

for i=1:10
QPS_A(i)=Qpls_A(i)*PS(i);
end
SQPS_A=sum(QPS_A);

fprintf('Umnožak realiziranih količina i profitne stope za model A:\n');
display(QPS_A)
fprintf('Suma umnožaka realiziranih količina i profitne stope za model A:\n');
display(SQPS_A)

PPS_A=SQPS_A/SQ_A;
fprintf('Prosječna profitna stopa po proizvodu za model A:\n');
display(PPS_A)
assignin('base', 'PPS_A', PPS_A);
for i=1:6
for j=1:10

DQpl_A(i,j)=abs((x(i,j)-Qp(i,j))/Qp(i,j));

end
end
fprintf('Odstupanje od srednje vrijednosti realizacije za model A:\n');
display(DQpl_A)

for i=1:10
DQpls_A=sum(DQpl_A)/10;
end
DSQ_A=sum(DQpls_A)/10;

fprintf('Prosječna odstupanja od srednje vrijednosti realizacije za model A:\n');
display(DQpls_A)
fprintf('Prosječno odstupanje količina za model A:\n');
display(DSQ_A)
assignin('base', 'DQpls_A', DQpls_A);
assignin('base', 'DSQ_A', DSQ_A);
% ----------------------------------------

% Prosjecna odstupanja za Model C

for i=1:10
Qpls_C=sum(Qpl)/10;
end
SQ_C=sum(Qpls_C);

fprintf('Srednje vrijednosti realizacije proizvoda za model C:\n');
display(Qpls_C)
fprintf('Suma srednjih vrijednosti realizacije proizvoda za model C:\n');
display(SQ_C)

for i=1:10
QPS_C(i)=Qpls_C(i)*PS(i);
end
SQPS_C=sum(QPS_C);

fprintf('Umnožak realiziranih količina i profitne stope za model C:\n');
display(QPS_C)
fprintf('Suma umnožaka realiziranih količina i profitne stope za model C:\n');
display(SQPS_C)
```

```
PPS_C=SQPS_C/SQ_C;

fprintf('Prosječna profitna stopa po proizvodu za model C:\n');
display(PPS_C)
assignin('base', 'PPS_C', PPS_C);
for i=1:6
for j=1:10
DQpl_C(i,j)=abs((Qpl(i,j)-Qp(i,j))/Qp(i,j));

end
end
fprintf('Odstupanje od srednje vrijednosti realizacije za model C:\n');
display(DQpl_C)

for i=1:10
DQpls_C=sum(DQpl_C)/10;
end
DSQ_C=sum(DQpls_C)/10;

fprintf('Prosječna odstupanja od srednje vrijednosti realizacije za model C:\n');
display(DQpls_C)
fprintf('Prosječno odstupanje količina za model C:\n');
display(DSQ_C)
assignin('base', 'DQpls_C', DQpls_C);
assignin('base', 'DSQ_C', DSQ_C);
% ----------------------------------------

% Prosjecna odstupanja za Model B

for i=1:10
Qpls_B=sum(x1)/10;
end
SQ_B=sum(Qpls_B);

fprintf('Srednje vrijednosti realizacije proizvoda za model B:\n');
display(Qpls_B)
fprintf('Suma srednjih vrijednosti realizacije proizvoda za model B:\n');
display(SQ_B)

for i=1:10
QPS_B(i)=Qpls_B(i)*PS(i);
end
SQPS_B=sum(QPS_B);

fprintf('Umnožak realiziranih količina i profitne stope za model B:\n');
display(QPS_B)
fprintf('Suma umnožaka realiziranih količina i profitne stope za model B:\n');
display(SQPS_B)

PPS_B=SQPS_B/SQ_B;
fprintf('Prosječna profitna stopa po proizvodu za model B:\n');
display(PPS_B)
assignin('base', 'PPS_B', PPS_B);
for i=1:6
for j=1:10

DQpl_B(i,j)=abs((x1(i,j)-Qp(i,j))/Qp(i,j));

end
end
fprintf('Odstupanje od srednje vrijednosti realizacije za model B:\n');
display(DQpl_B)

for i=1:10
DQpls_B=sum(DQpl_B)/10;
end
DSQ_B=sum(DQpls_B)/10;
```

```
fprintf('Prosječna odstupanja od srednje vrijednosti realizacije za model B:\n');
display(DQpls_B)
fprintf('Prosječno odstupanje količina za model B:\n');
display(DSQ_B)
assignin('base', 'DQpls_B', DQpls_B);
assignin('base', 'DSQ_B', DSQ_B);

% ----------------------------------------

% Prosjecna odstupanja za Model D

for i=1:10
Qpls_D=sum(Qpl1)/10;
end
SQ_D=sum(Qpls_D);


fprintf('Srednje vrijednosti realizacije proizvoda za model D:\n');
display(Qpls_D)
fprintf('Suma srednjih vrijednosti realizacije proizvoda za model D:\n');
display(SQ_D)

for i=1:10
QPS_D(i)=Qpls_D(i)*PS(i);
end
SQPS_D=sum(QPS_D);

fprintf('Umnožak realiziranih količina i profitne stope za model D:\n');
display(QPS_D)
fprintf('Suma umnožaka realiziranih količina i profitne stope za model D:\n');
display(SQPS_D)

PPS_D=SQPS_D/SQ_D;
fprintf('Prosječna profitna stopa po proizvodu za model D:\n');
display(PPS_D)
assignin('base', 'PPS_D', PPS_D);
for i=1:6
for j=1:10

DQpl_D(i,j)=abs((Qpl1(i,j)-Qp(i,j))/Qp(i,j));

end
end
fprintf('Odstupanje od srednje vrijednosti realizacije za model D:\n');
display(DQpl_D)

for i=1:10
DQpls_D=sum(DQpl_D)/10;
end
DSQ_D=sum(DQpls_D)/10;

fprintf('Prosječna odstupanja od srednje vrijednosti realizacije za model D:\n');
display(DQpls_D)
fprintf('Prosječno odstupanje količina za model D:\n');
display(DSQ_D)
assignin('base', 'DQpls_D', DQpls_D);
assignin('base', 'DSQ_D', DSQ_D);

fprintf('Prosječno odstupanje količina za sve modele:\n');
display(DSQ_A)
display(DSQ_B)
display(DSQ_C)
display(DSQ_D)


open('testiranje_modela_optimizacije.rpt') ;
```

```
%==================================================================================

%====== SIMPLEX METODA LINEARNOG PROGRAMIRANJA
    function [X,fval]=simplex_metoda(C,A,B,lb,ub)

    % Start with the default options
    options = optimset;
    % Modify options setting
    options = optimset(options,'Display', 'final');
    options = optimset(options,'Diagnostics', 'on');
    options = optimset(options,'LargeScale', 'off');
    options = optimset(options,'Simplex', 'on');

    %[x]=linprog(f,[],[],A,b);
    [X,fval,exitflag,output]=linprog(C,A,B,[],[],lb,ub,[],options);
    % [X,fval,exitflag,output]=linprog(C,A,B,Aeq,Beq,lb,ub,x0,options);
```

PRILOG 9.2.-2 Rezultati ispitivanja različitih modela optimiranja u raznim uvjetima *- primjer proizvodnje autostakla*

I. Ispitivanje u uvjetima malog rizika i malog učešća očekivanih i neočekivanih narudžbi

Proizvodni plan za model A:

(Qpl)A =

104	124	151	178	188	225	205	202	218	221
114	138	161	187	211	234	209	215	224	236
124	138	175	189	225	243	217	222	235	234
128	149	184	197	224	268	272	229	246	253
123	144	174	198	215	259	220	224	233	248
118	136	162	176	199	232	198	212	224	233

Prosječna profitna stopa po proizvodu za model A: PPS_A = 0.088581813791437

Prosječno odstupanje količina za model A: DSQ_A = 0.061819959373455

Proizvodni plan za model B:

(Qpl)B =

101	119	145	171	182	216	223	209	230	230
109	134	156	179	202	224	229	226	233	245
120	134	170	182	216	234	237	230	244	243
124	145	177	188	215	256	263	241	279	279
119	140	169	190	205	249	235	235	244	260
115	132	156	168	191	223	220	220	233	242

Prosječna profitna stopa po proizvodu za model B: PPS_B = 0.088150905247325

Prosječno odstupanje količina za model B: DSQ_B = 0.037683401982604

Proizvodni plan za model C:

Qpl =

104	124	127	150	161	225	205	237	251	255
114	138	139	187	176	234	209	250	263	236
124	116	175	189	184	244	252	222	235	277
103	149	184	197	224	240	272	229	288	289
102	116	150	198	179	259	267	266	278	284
118	136	138	176	167	232	229	251	224	269

Prosječna profitna stopa po proizvodu za model C: PPS_C = 0.087773612051373

Prosječno odstupanje količina za model C: DSQ_C = 0.051747301618475

Proizvodni plan za model D:

```
Qpl =
104   102   151   150   161   225   229   202   251   255
091   138   161   187   211   201   198   250   278   279
124   138   150   188   225   244   217   222   278   277
128   149   156   172   224   268   272   270   283   253
102   117   138   198   215   259   267   258   278   248
091   136   140   176   199   232   236   246   263   233

Prosječna profitna stopa po proizvodu za model D:    PPS_D = 0.087809735818496

Prosječno odstupanje količina za model D:      DSQ_D = 0.032312252603709
```

II. Ispitivanje u uvjetima većeg rizika, velikog učešća očekivanih i malog učešća neočekivanih narudžbi

Proizvodni plan za model A:

```
(Qpl)A =
110   131   160   189   199   234   180   190   205   208
121   146   171   198   224   238   186   202   211   222
131   146   186   200   238   237   204   209   221   220
136   158   195   209   237   284   237   215   227   238
130   153   184   210   228   260   199   211   219   233
125   144   172   187   211   227   186   199   211   219

Prosječna profitna stopa po proizvodu za model A:    PPS_A = 0.089130776561961

Prosječno odstupanje količina za model A:      DSQ_A = 0.096603212713090
```

Proizvodni plan za model B:

```
(Qpl)B =
102   121   147   171   178   220   220   207   226   229
109   136   154   178   203   224   231   223   232   245
119   132   171   182   214   233   233   235   248   243
125   146   180   189   214   257   261   235   281   278
121   141   170   189   206   253   232   237   241   254
116   133   158   168   190   220   219   217   232   242

Prosječna profitna stopa po proizvodu za model B:    PPS_B = 0.088208104116124

Prosječno odstupanje količina za model B:      DSQ_B = 0.039922336443162
```

Proizvodni plan za model C:

```
(Qpl)C =
082   098   117   185   196   234   185   259   261   276
115   108   167   194   219   243   255   206   215   290
129   111   182   197   234   196   208   286   289   293
133   155   191   205   233   279   283   287   231   243
128   111   144   206   172   220   278   277   289   295
110   141   131   183   207   241   246   204   278   224
```

Prosječna profitna stopa po proizvodu za model C: PPS_C = 0.087463911493815

Prosječno odstupanje količina za model C: DSQ_C = 0.082126270730082

Proizvodni plan za model D:

(Qpl)D =

082	098	117	185	196	234	185	259	261	276
115	108	167	194	219	243	255	206	215	290
129	111	182	197	234	196	208	286	289	293
133	155	191	205	233	279	283	287	231	243
128	111	144	206	172	220	278	277	289	295
110	141	131	183	207	241	246	204	280	224

Prosječna profitna stopa po proizvodu za model D: PPS_D = 0.087714470097155

Prosječno odstupanje količina za model D: DSQ_D = 0.036599602788462

III. Ispitivanje u uvjetima većeg rizika, malog učešća očekivanih i velikog učešća neočekivanih narudžbi

Proizvodni plan za model A:

(Qpl)A =

110	131	160	189	199	234	180	190	205	208
121	146	171	198	224	238	186	202	211	222
131	146	186	200	238	237	204	209	221	220
136	158	195	209	237	284	237	215	227	238
130	153	184	210	228	260	199	211	219	233
125	144	172	187	211	227	186	199	211	219

Prosječna profitna stopa po proizvodu za model A: PPS_A = 0.089130776561961

Prosječno odstupanje količina za model A: DSQ_A = 0.096603212713090

Proizvodni plan za model B:

(Qpl)B =

106	126	155	182	191	230	195	198	213	216
117	141	165	191	216	239	196	210	221	230
127	141	180	193	229	241	212	217	230	229
131	152	188	201	228	275	259	226	237	248
126	147	177	202	219	264	207	219	228	243
120	139	165	180	202	230	194	209	219	228

Prosječna profitna stopa po proizvodu za model B: PPS_B = 0.088789285365274

Prosječno odstupanje količina za model B: DSQ_B = 0.074892989426779

Proizvodni plan za model C:

(Qpl)C =

108	129	157	185	153	185	185	194	261	276
119	144	127	194	162	240	255	279	215	227
098	144	182	197	234	254	208	213	226	293
133	116	153	205	196	279	283	220	300	301
098	150	143	206	224	262	278	215	289	295
123	108	168	143	192	241	190	268	215	285

Prosječna profitna stopa po proizvodu za model C: PPS_C = 0.087930822159067

Prosječno odstupanje količina za model C: DSQ_C = 0.080533821201808

Proizvodni plan za model D:

(Qpl)D =

1.08	1.29	1.57	1.85	1.53	1.85	1.85	1.94	2.61	2.76
1.19	1.44	1.27	1.94	1.62	2.40	2.55	2.79	2.15	2.27
0.98	1.43	1.82	1.97	2.34	2.54	2.08	2.13	2.26	2.93
1.33	1.16	1.53	2.05	1.96	2.79	2.83	2.20	3.00	3.01
0.98	1.50	1.43	2.06	2.24	2.62	2.78	2.15	2.89	2.95
1.23	1.08	1.68	1.43	1.92	2.41	1.90	2.68	2.15	2.85

Prosječna profitna stopa po proizvodu za model D: PPS_D = 0.087892007527106

Prosječno odstupanje količina za model D: DSQ_D = 0.069342400658681

IV. Ispitivanje u uvjetima velikog rizika i velikog učešća očekivanih i neočekivanih narudžbi

Proizvodni plan za model A:

(Qpl)A =

112	134	163	192	203	233	176	186	201	203
123	149	174	202	228	236	182	198	206	217
134	149	189	204	243	235	200	204	216	215
138	161	199	213	242	289	224	211	222	233
133	156	188	214	232	258	195	206	214	228
127	147	175	190	215	226	182	195	206	214

Prosječna profitna stopa po proizvodu za model A: PPS_A = 0.089303946171477

Prosječno odstupanje količina za model A: DSQ_A = 0.107849798827137

Proizvodni plan za model B:

(Qpl)B =

104	124	150	173	184	221	214	205	221	222
112	138	160	183	207	227	215	218	233	240
125	137	175	185	225	227	220	230	239	244
128	146	180	193	219	260	266	233	280	257
121	141	175	193	208	254	236	228	234	249
118	133	159	170	194	227	216	213	225	237

Prosječna profitna stopa po proizvodu za model B: PPS_B = 0.088379755405980

Prosječno odstupanje količina za model B: DSQ_B = 0.050520062457451

Proizvodni plan za model C:

(Qpl)C =

110	096	160	184	149	182	243	190	266	281
121	137	124	139	159	248	260	202	295	296
096	109	130	200	212	259	204	292	295	299
097	114	195	153	180	284	288	293	305	306
130	153	141	194	228	275	199	211	295	301
125	144	172	187	211	227	251	199	211	219

Prosječna profitna stopa po proizvodu za model C: PPS_C = 0.087599540696487

Prosječno odstupanje količina za model C: DSQ_C = 0.091299303509898

Proizvodni plan za model D:

(Qpl)D =

110	096	160	184	149	182	243	190	266	281
121	137	124	139	159	248	260	202	295	296
096	109	130	200	212	259	204	292	295	299
097	114	195	153	180	284	288	293	305	306
130	153	141	194	228	275	199	211	295	301
125	144	172	187	211	227	251	199	211	219

Prosječna profitna stopa po proizvodu za model D: PPS_D = 0.087621314112031

Prosječno odstupanje količina za model D: DSQ_D = 0.046706441209251

ŽIVOTOPIS

Borislav Gordić rođen je 17. listopada 1951. godine u Virovitici. Osnovnu školu "Marin Držić" i srednju školu "Braća Ribar" završio je u Zagrebu. Godine 1970. započeo je sa studijem proizvodnog strojarstva na Fakultetu strojarstva i brodogradnje u Zagrebu gdje je diplomirao u travnju 1975. godine. Zapošljava se u tvornici posuđa "Gorica" u Dugom Selu gdje je obavljao poslove od tehnologa do direktora razvojno-tehničkih poslova. U tom je razdoblju upisao i 1980. godine magistrirao na Fakultetu strojarstva i brodogradnje u Zagrebu s temom "Optimizacija operativnog planiranja proizvodnje". U razdoblju 1983.- 1985. bio je pomoćnik direktora Poslovne zajednice za malu privredu Hrvatske, a od 1986.do 1990. bio je direktor proizvodnje i glavni direktor Tvornice metalnog namještaja "Jadran" u Zagrebu. U tom razdoblju je izabran za znanstvenog asistenta i ostvaruje suradnju sa Zavodom za organizaciju Fakulteta strojarstva i brodogradnje. Godine 1990. započinje s privatnim poslom kao konzultant za razvoj i investicije te upravljanje proizvodnjom, koje je i područje njegovog znanstvenog rada. Izradio je preko 50 studija i investicijskih programa te sudjelovao u razvojnim projektima za nekoliko većih proizvodnih poduzeća i vodio dva značajna investicijska projekta. Sudjelovao je u jednom znanstvenom istraživanju i međunarodnom poslijediplomskom studiju i ima tri novija objavljena rad. Član je Hrvatske udruge za PLM i surađuje s Veleučilištem u Varaždinu. Oženjen je i otac je dvoje odrasle djece.

Objavljeni radovi:

1. *"Doprinos određivanju kriterija i mjerila za ocjenjivanje operativnog planiranja i praćenja proizvodnje"*, Tehnički vjesnik, 2011., broj 1, godište 18, str.109-115

2. *"Mogućnosti razvoja operativnog planiranja i praćenja proizvodnje"*, Zbornik radova sa međunarodne znanstvene konferencije MOTSP, Hrvatska, lipanj 2011., str. 236-242.

3. *"Ispitivanje metode korektivnog optimiranja"*, Zbornik radova sa međunarodne znanstvene konferencije MOTSP, Hrvatska, lipanj 2013.

BIOGRAPHY

Borislav Gordić was born October 17th, 1951 in Virovitica, Republic of Croatia. He has finished primary and high school in Zagreb. In 1970 he started with studies of industrial engineering at the Faculty of Mechanical Engineering and Naval Architecture, University of Zagreb, where he has graduated in April 1975. He started to work in dishes' production factory "Gorica" in Dugo Selo where he has performed duties from Technologist to Development and technical works manager. In that period he started with postgraduate studies and in the year 1980 he achieved the Master's degree at the Faculty of Mechanical Engineering and Naval Architecture, University of Zagreb, with thesis theme "Optimization of operational production planning". Between 1983 and 1985 he worked as Assistant manager in "Business Association of Small Enterprises of Croatia". From 1986 to 1990 he was Production manager and General manager in Metal Furniture Factory "Jadran" in Zagreb. In that period he was also promoted to Research assistant at the Faculty and he started to cooperate with Department of Industrial Engineering and Management on the Faculty of Mechanical Engineering and Naval Architecture, University of Zagreb. In 1990 he started with private business as Consultant for development and investments, including production management, which is the field of his scientific work. He developed more than 50 studies and investment programmes for several bigger companies and he was a project manager on two respectable investment projects. He participated in one scientific research and international postgraduate study and he has three new published papers. He is a member of Croatian Association for PLM and he cooperates with Polytechnics in Varaždin. He is married and has two adult children.

Published papers:

1. *"A Contribution to the Determination of Criteria and Measures for Evaluating Operational Planning and Production Control"*, Technical Gazette, 2011., No. 1, Volume 18, pages 109-115
2. *"Possibilities for the Development of Operational Planning and Production Control"*, International Scientific Conference MOTSP, Croatia, June 2011, pages 236-242.
3. *"Testing of Corrective Optimization Method"*, Internatioonal Scientific Conference MOTSP, Croatia, June 2013