

Simulacijski okvir za određivanje optimalnoga vremenskog iskorištenja višepredmetnoga linijskoga proizvodnog sustava

Ištoković, David

Doctoral thesis / Disertacija

2021

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Rijeka, Faculty of Engineering / Sveučilište u Rijeci, Tehnički fakultet**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:190:762624>

Rights / Prava: [In copyright](#) / [Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-04-19**



Repository / Repozitorij:

[Repository of the University of Rijeka, Faculty of Engineering](#)



SVEUČILIŠTE U RIJECI

TEHNIČKI FAKULTET

David Ištoković

**SIMULACIJSKI OKVIR ZA ODREĐIVANJE
OPTIMALNOGA VREMENSKOG ISKORIŠTENJA
VIŠEPREDMETNOGA LINIJSKOGA
PROIZVODNOG SUSTAVA**

DOKTORSKA DISERTACIJA

Rijeka, 2021.

SVEUČILIŠTE U RIJECI

TEHNIČKI FAKULTET

David Ištoković

**Simulacijski okvir za određivanje optimalnoga
vremenskog iskorištenja višepredmetnoga
linijskoga proizvodnog sustava**

DOKTORSKA DISERTACIJA

Mentor: prof. dr. sc. Mladen Perinić

Rijeka, 2021.

UNIVERSITY OF RIJEKA
FACULTY OF ENGINEERING

David Ištoković

**A simulation framework for determining the
optimal time utilization of a hybrid flow shop**

DOCTORAL THESIS

Rijeka, 2021.

Mentor doktorske disertacije: prof. dr. sc. Mladen Perinić

Doktorska disertacija obranjena je dana _____ na Tehničkom fakultetu Sveučilišta u Rijeci, pred povjerenstvom u sastavu:

1. prof. dr. sc. Zoran Jurković, Tehnički fakultet, Sveučilište u Rijeci
2. prof. dr. sc. Goran Šimunović, Strojarski fakultet, Sveučilište u Slavonskom Brodu
3. prof. dr. sc. Miran Brezočnik, Fakulteta za strojništvo, Univerza v Mariboru, Slovenija

Veliku zahvalnost, u prvom redu, dugujem svome mentoru prof. dr. sc. Mladenu Periniću koji mi je prenošenjem svojih znanja i iskustava pomogao tijekom izrade ove doktorske disertacije. Zahvaljujem mu na svom strpljenju i vremenu odvojenom na moja brojna pitanja.

Također, zahvaljujem se svim radnim kolegama i kolegicama, profesorima i profesoricama, koji su savjetima i ohrabrujućim riječima usmjeravali me na pravi put.

Posebnu zahvalnost iskazujem bratu i roditeljima koji su uvijek bili uz mene, i u sretnim i u teškim trenucima, i bez kojih ništa od ovog ne bi bilo moguće.

I na kraju, najveću zahvalnost posvećujem svojoj supruzi, na strpljenju, staloženosti i vjeri u mene, kao i svome sinu koji je postao dodatni motiv za daljnji rad.

SAŽETAK

Planiranjem proizvodnje osigurava se postojanje i konkurentnost proizvodnih poduzeća na tržištu. Osobito su važni poslovi operativne pripreme temeljem kojih se definira vremenski plan odvijanja proizvodnje i osiguravaju svi potrebni resursi. Kod proizvodnje tehnološki složenih obitelji proizvoda u modelu višepredmetnoga linijskoga proizvodnog sustava ograničene fleksibilnosti s proizvodnim procesom koji se odvija u više segmenata uobičajena je visoka iskorištenost proizvodnog sustava što sužava mogućnost pronalaska ekonomičnog rješenja. Iz toga proizlazi potreba za razvojem simulacijskog okvira za određivanje veličine jedinične serije i redoslijeda ulaza jedinične serije u proizvodni proces, dva glavna područja poboljšanja mjera uspješnosti. Razlog razmatranja ovih dviju veličina leži u tome što različite vrijednosti veličine jedinične serije i redoslijeda ulaza proizvoda direktno utječu na vrijeme potrebno za odvijanje proizvodnog procesa. Rješavanje problema određivanja veličine jedinične serije i redoslijeda ulaza jedinične serije među najtežim je zadacima planiranja proizvodnje. Pogotovo ako se posebna pozornost posveti utjecaju pripremno-završnog vremena ovisnog o slijedu, kao i raspoloživosti proizvodnih kapaciteta te dostupnosti transportne opreme na konačan rezultat. Implementiranjem izrađenog matematičkog modela u razvijeni simulacijski okvir stvorena je podloga za razvoj znanstveno zasnovane metode. Takav simulacijski okvir omogućava eksperimentiranje s računalnim matematičkim modelom fizikalnog sustava. Proizvodni proces prikazan je kao diskretna simulacija događaja podržana genetskim algoritmom. Primjenom i razvijanjem procedura unutar genetskog algoritma omogućeno je određivanje optimalnoga vremenskog iskorištenja višepredmetnoga linijskoga proizvodnog sustava. Razvijeni računalom potpomognuti simulacijski okvir provjeren je na konkretnom primjeru iz realnog sektora te na jednostavan i vizualno jasan način služi kao potpora pri planiranju proizvodnje. Simulacijski okvir primjenjiv je u raznim proizvodnim okruženjima, pogotovo onim koji se bave proizvodnjom širokog asortimana tehnološki složenih proizvoda.

ABSTRACT

Production planning ensures the existence and competitiveness in the market, with particularly important tasks of operational preparation on the basis of which the production schedule is defined and all the necessary resources are provided. In the production of technologically complex product families in a hybrid flowshop system with limited flexibility and multi-stages production process, the high utilization of the production system is common, which limits the possibility of finding an economical solution. This implies the need to develop a simulation framework for determining the size and entry-sequence of batches into the production process, a two main areas for improving performance measures. The reason for considering these two values lies in the fact that different values of batch size and entry-sequence of batches directly affect the duration of the production process. Solving the problem of determining batch size and schedule is among the most difficult tasks of production planning. Especially if special attention is paid to the influence of sequence-dependent setup times, the availability of production capacities and the availability of transport equipment on the final result. Implementing the created mathematical model in the developed simulation framework, a basis for the development of a scientifically based method was created. Such a simulation framework allows experimentation with a computer mathematical model of a physical system. The production process is presented as a discrete event simulation supported by a genetic algorithm. Applying and developing procedures within the genetic algorithm will allow determining optimal time utilization of a hybrid flow shop. The developed computer-assisted simulation framework has been tested on a concrete example from the real sector and serves as a support in production planning in a simple and visually clear way. The simulation framework is applicable in various production environments, especially those engaged in the production of a wide range of technologically complex products.

KLJUČNE RIJEČI

Višepredmetni linijski proizvodni sustav

Optimalno vremensko iskorištenje

Simulacijski okvir

Redoslijed ulaza jediničnih serija proizvoda

Veličina jediničnih serija proizvoda

Simulacija diskretnih događaja

Genetski algoritam

KEYWORDS

Hybrid flow shop

Optimal time utilization

Simulation framework

Scheduling

Lot size

Discrete event simulation

Genetic algorithm

SADRŽAJ

SAŽETAK.....	i
ABSTRACT	ii
KLJUČNE RIJEČI	iii
Poglavlje 1: UVOD	1
1.1. Postavljanje problema	1
1.2. Pregled dosadašnjih istraživanja	3
1.3. Svrha i cilj istraživanja	8
1.4. Hipoteza istraživanja	8
1.5. Metodologija istraživanja	9
1.6. Struktura doktorske disertacije	10
Poglavlje 2: PLANIRANJE REDOSLIJEDA I VELIČINE JEDINIČNIH SERIJA VLPS-A	12
2.1. Terminiranje proizvodnje	15
2.1.1. Planiranje redoslijeda	19
2.1.2. Planiranje jediničnih serija	19
2.2. Klasifikacija problema terminiranja proizvodnje	21
2.2.1. Izgled sustava	23
2.2.2. Pravila o zalihama	23
2.2.3. Jedinične serije	23
2.2.4. Vremena izrade	24

2.2.5. Obrasci potražnje.....	24
2.2.6. Ograničenja	24
2.2.7. Troškovi	24
2.2.8. Stupanj nesigurnosti	25
2.2.9. Okruženje	25
2.3. Višepredmetni linijski proizvodni sustavi.....	25
2.4. Notacija višepredmetnih linijskih proizvodnih sustava	28
2.4.1. Karakteristike i ograničenja izrade.....	28
2.4.2. Funkcije cilja	29
2.4.3. Okruženje VLPS-a	32
Poglavlje 3: METODE OPTIMIZACIJE I SIMULACIJE	34
3.1. Metode rješavanja problema planiranja redoslijeda i veličine jediničnih serija	34
3.1.1. Egzaktne metode	35
3.1.2. Heurističke metode.....	36
3.1.3. Ekspertni sustavi	36
3.1.4. Pravila otpreme	37
3.1.5. Umjetne neuronske mreže	38
3.1.6. Metaheuristika	38
3.1.7. Hibridni pristupi	40
3.2. Genetski algoritmi	41
3.2.1. Predstavljanje	42
3.2.2. Selekcija	43
3.2.3. Genetski operatori	44

3.2.4. Uvjet zaustavljanja	47
3.3. Metode simulacije	48
3.3.1. Sustav	50
3.3.2. Stanje sustava	50
3.3.3. Realni sustav	51
3.3.4. Model	51
3.3.5. Koncept simulacije	52
3.3.6. Simulacijski model	53
3.4. Simulacija diskretnih događaja	55
3.4.1. Primjena simulacije diskretnih događaja.....	57
Poglavlje 4: OPTIMALNO VREMENSKO ISKORIŠTENJE VLPS-a	58
4.1. Ciklus izrade.....	59
4.1.1. Vrijeme kontrole	60
4.1.2. Vrijeme transporta.....	60
4.1.3. Vrijeme međuskladištenja	61
4.1.4. Vrijeme nepouzdanosti proizvodnog kapaciteta	63
4.1.5. Vrijeme izrade škarta.....	63
4.1.6. Ostala vremena međuoperacijskih čekanja	64
4.2. Pripremno-završno vrijeme	66
4.3. Utjecaj redoslijeda i veličine jedinične serije na ciklus izrade i pripremno-završno vrijeme.....	67
4.4. Formulacija troškova proizvodnje.....	71
4.4.1. Trošak proizvodne opreme.....	72

4.4.2. Trošak alata	73
4.4.3. Trošak škarta	73
4.4.4. Trošak skladištenja	73
4.4.5. Trošak energije	74
4.4.6. Trošak repromaterijala	75
4.4.7. Trošak zakašnjele isporuke	75
Poglavlje 5: SIMULACIJSKI OKVIR.....	77
5.1. Simulacijsko-optimizacijski pristup	78
5.1.1. Programski paketi za simulacijsko-optimizacijski pristup	79
5.2. Simulacijski okvir za određivanje optimalnog vremenskog iskorištenja.....	80
5.3. Simulacijski model.....	82
5.4. Određivanje veličine jediničnih serija i redoslijeda ulaska jediničnih serija u sustav ..	85
5.5. GA optimizacija	87
5.5.1. Predstavljanje jedinki	88
5.5.2. Odabir jedinki za reprodukciju.....	88
5.5.3. Križanje u dvije točke i mutacija dodjelom	89
5.5.4. Probabilistička selekcija nove populacije	91
5.5.5. Uvjet zaustavljanja	91
5.6. Simulacijski eksperiment	91
Poglavlje 6: STUDIJA SLUČAJA I REZULTATI EKSPERIMENTALNIH ISTRAŽIVANJA	93
6.1. Izrada simulacijskog modela VLPS-a	97
6.2. Verifikacija i validacija simulacijskog modela	104

6.3. Primjena simulacijskog okvira za studiju slučaja	106
6.3.1. Slučaj 1 - najraniji završetak proizvodnje	107
6.3.2. Slučaj 2 - određivanje optimalnoga vremenskog iskorištenja za minimalne vrijednosti srednjeg ciklusa izrade i ukupnog pripremno-završnog vremena uz osnovni uvjet pravovremene isporuke	113
6.3.3. Slučaj 3 - određivanje optimalnoga vremenskog iskorištenja za minimalne troškove proizvodnje i osnovni uvjet isporuke na vrijeme	119
Poglavlje 7: ZAKLJUČAK	124
LITERATURA.....	128
POPIS OZNAKA I KRATICA	141
POPIS SLIKA	147
POPIS TABLICA.....	151
ŽIVOTOPIS	152
POPIS OBJAVLJENIH RADOVA	154


Poglavlje 1: UVOD

Uvodnim poglavljem se opisuje motivacija za ovim znanstvenim istraživanjem potaknuta problemom iz realnog sektora. Na osnovi istražene znanstvene literature definirani su cilj i svrha istraživanja. Slijedom toga, formulirana je radna hipoteza te tri pomoćne hipoteze. Na kraju slijede metodologija istraživanja te kratak opis narednih poglavlja.

1.1. Postavljanje problema

Sve veći tržišni zahtjevi koji proizlaze iz povećanja kompleksnosti proizvoda i povećanja različitih varijanti proizvoda uz promjenjive opsege proizvodnje uvjetuju da industrijski proizvodni sustavi postaju složeniji gledajući i sa tehnološkog stajališta i sa stajališta upravljanja proizvodnjom. Jedan od ključnih faktora u osiguranju opstanka i konkurentnosti proizvodnih poduzeća je planiranje proizvodnje (Pinedo, 2016.). Planiranje proizvodnje zapravo predstavlja jedno kompleksno područje s vrlo važnim utjecajem na efikasnost proizvodnog poduzeća. Osnovni zadatak planiranja proizvodnje može se prikazati pomoću trinoma kvaliteta - troškovi - vrijeme, slika 1.1., odnosno važno je osigurati potrebnu kvalitetu proizvoda, uz što manje troškove proizvodnje i pravovremenu isporuku. Važnu ulogu u ostvarenju tog trinoma imaju aktivnosti operativne pripreme koje obuhvaćaju poslove operativnog planiranja, lansiranja i praćenja proizvodnje, transporta, osiguranja alata i

repromaterijala, odnosno aktivnosti pomoću kojih se definira vremenski plan odvijanja proizvodnje i osiguravaju svi potrebni resursi.



Slika 1.1. Inženjerski trinom - potrebno je proizvesti dovoljno kvalitetan proizvod uz što manje troškove proizvodnje za predviđeni vremenski period

Kod detaljnog planiranja proizvodnje među najtežim zadacima nalaze se odluke vezane za planiranje veličine jediničnih serija i planiranje redoslijeda jediničnih serija za određeni proizvod i/ili grupu proizvoda. Problem planiranja veličine jediničnih serija podrazumijeva dijeljenje ukupne proizvodne količine u manje cjeline, jedinične serije, s ciljem optimizacije određenih kriterija. Nakon toga, određivanjem redoslijeda se raspoloživi proizvodni resursi dodjeljuju jediničnim serijama tijekom određenog vremenskog razdoblja (Mendez i sur., 2006.). Određivanje redoslijeda i veličine jedinične serije oblik je odlučivanja koji ima presudnu ulogu u proizvodnoj i uslužnoj industriji. Proizvodna poduzeća moraju isporučiti robu ili uslugu na vrijeme kako bi se izbjegli gubici i osigurala konkurentnost (Pinedo, 2005.).

Prema tome, nije teško prepoznati da je učinkovito planiranje redoslijeda i planiranje veličine jediničnih serija proizvoda vitalno za opstanak i konkurentnost industrijskih proizvodnih poduzeća. Ti problemi potaknuli su zanimanje kako akademske zajednice, tako i industrijske zajednice. O tome svjedoči i velik broj znanstvenih radova s primjenom u realnom sektoru.

Planiranje redoslijeda i planiranje veličine jediničnih serija proizvoda predstavlja izuzetno zahtjevan i težak zadatak, pogotovo u današnjem okruženju. Trenutno se proizvodna poduzeća koriste raznim metodama, modulima i tehnikama za planiranje koji se baziraju na determinističkim algoritmima (Frantzen, 2013.). Kako deterministički algoritmi ne uključuju brojne nesigurnosti iz realnog okruženja, poput kvara na stroju, pojave škarta i sličnog, potrebno

je osigurati određeni vid podrške koji će omogućiti kvalitetnije i prije svega jednostavnije planiranje i vođenje proizvodnje.

1.2. Pregled dosadašnjih istraživanja

Posljednjih godina u ovom području uloženi su značajni istraživački napor u razvoju optimizacijskih pristupa. Iako je postignut značajan napredak, za rješavanje velikog broja operativnih pitanja (npr. promjenjiva ili fiksna veličina serije, pravila skladištenja i transporta, priprema i raspored radnog mjesta, zamjena alata) kao i različitih ciljeva (npr. završetak proizvodnje, zakašnjelost, iskoristivost proizvodne opreme ili minimiziranje troškova) mnoga pitanja vezana uz specifične mogućnosti metoda i dalje su ostala neriješena. Pogotovo kada se u obzir uzmu prednosti i ograničenja različitih modela optimizacije korištenih u literaturi i veličina problema koji se realno mogu riješiti s tim modelima.


Kako bi se osiguralo dobivanje najnovijih informacija o trenutnim dostignućima, ograničenjima i trendovima u polju planiranja proizvodnje provedena je opsežna i sistematska analiza literature, bazirajući se na operativnoj pripremi koja uključuje vrijeme/trošak pripreme i raspored radnog mjesta ovisnom o slijedu kako bi se stvorila osnova za identifikaciju i provedbu analize utjecajnih čimbenika na planiranje proizvodnog procesa.

Radeći na pronalasku boljih načina planiranja proizvodnje, mnogi autori su razvili različite stohastičke modele. Pregled publikacija s fokusom na planiranje proizvodnih operacija i planiranja redoslijeda dali su Negahban i Smith (2014.). U svojoj knjizi, Framinan i sur. (2014.) predstavljaju integrirani prikaz na modele, metode i alate koji se koriste prilikom planiranja proizvodnje. Također, prikazuju elemente koji čine sustav planiranja, zajedno s analizom proizvodnog konteksta u kojem će se sustav planiranja primijeniti. Pinedo (2016.) pruža sveobuhvatan pregled važnih teorijskih modela u literaturi o planiranju kao i pregled značajnih problema planiranja redoslijeda koji se javljaju u realnom okruženju.

Kod postrojenja sa serijskim tipom proizvodnje, prema Mendez i sur. (2006.) izgled sustava i raspored radnih mjesta unutar sustava imaju značajan utjecaj na složenost problema. Ovisno da li se sustav sastoji od jedne ili više faza, pri čemu svaka faza može sadržavati jedan ili više paralelnih strojeva. Također, ovisi da li se proizvodi kreću kroz sustav jednosmjerno ili postoji povratni hod. Problem planiranja redoslijeda u protočnim sustavima, Ribas i sur. (2010.)

klasificiraju na: probleme planiranja redoslijeda u sustavima s jednom fazom proizvodnje gdje postoji više paralelnih strojeva koji mogu izvršiti radni zadatak, i probleme planiranja redoslijeda s više faza proizvodnje gdje svi radni zadaci zahtijevaju obradu na istim resursima te svi radni zadaci imaju zajedničku rutu. Pritom radni zadatak podrazumijeva tehnološki proces jednog promatranog proizvoda ili dijela, odnosno grupe proizvoda.

Promatrajući realno okruženje, višepredmetni linijski sustav (VLPS) je preferirani izbor za procesna ili diskretna proizvodna poduzeća za vođenje proizvodnje po narudžbi i masovne prilagodbe. VLPS se široko koristi u mnogim industrijama kao što su proizvodnja strojeva, proizvodnja automobila, proizvodnja elektronike i kemijska proizvodnja (Ribas i sur., 2010.). Karakterizira ga proizvodnja srednjih ili velikih količina više različitih vrsta tehnološki sličnih proizvoda. Pritom se proizvodi kreću jednosmjerno kroz proces te obrađuju na nekoliko radnih stanica. Unutar svake radne stanice može se nalaziti jedan ili više istovrsnih strojeva, gdje svaki stroj može obavljati najviše jednu operaciju u istom trenutku bilo kojeg radnog zadatka. Jednom započeta operacija na stroju ne smije se prekidati. Operacija nekog radnog zadatka ne može se izvesti sve dok se ne završe prethodne operacije tog radnog zadatka. Svi radni zadaci podliježu prioritetima koji ih ograničavaju na isti redoslijed obrade u svim fazama obrade (Kuo i sur., 2008.). Sve je veći broj radova koji se bave rješavanjem problema planiranja redoslijeda radnih zadataka (Vinod i sur., 2017.). O tome svjedoči i preko 3500 objavljenih radova, slika 1.2., indeksiranih u bazama *Web of Science Core Collection*. Iz iste slike, može se primijetiti kako je tendencija objavljenih radova u značajnom porastu u posljednjih deset godina.



Slika 1.2. Broj objavljenih radova koji se bave problemom planiranja redoslijeda u proteklih deset godina

VLPS također karakterizira velika produktivnost i mala fleksibilnost, što za posljedicu ima izrazito malo prostora za manipulaciju s vremenom za odvijanje proizvodnje kako ne bi došlo do kašnjenja s isporukom. Stoga vrijedi posvetiti veliku pažnju pripremno-završnom vremenu i dostupnosti transportne opreme.

Naderi i sur. (2009.) izjavili su da u mnogim stvarnim situacijama, poput automobilske, farmaceutske ili kemijske proizvodnje, aktivnosti pripreme i raspoređivanja radnog mjesta, kao što su čišćenje radnog mjesta ili zamjena alata, nisu samo potrebne između radnih zadataka nego su i ovisne o prethodnom radnom zadatku na istom proizvodnom kapacitetu. Pregledni članak vezan za problem planiranja redoslijeda gdje je pripremno-završno vrijeme ovisno o slijedu proizvoda (engl. *Sequence-Dependent Setup Time*, SDST) dao je Allahverdi (2015.). Isto tako, uveo je vrlo značajnu klasifikaciju i notaciju problema planiranja redoslijeda, temeljenih na proizvodnom okruženju, značajkama procesa, uvjetima postavljanja procesa i mjerama uspješnosti. S druge pak strane, Yang i sur. (2020.). su jedni od autora koji su se bavili problemom dostupnosti transportne opreme. Perinić (2004.) u svom radu uključuje dostupnost transportnog sredstva s ciljem optimiranja ciklusa izrade.

Osim problema s određivanjem redoslijeda, u literaturi se mogu pronaći brojni radovi vezani za problem planiranja jedinične serije (Cheng i sur., 2013., Beck i Glock, 2016.). Planiranje jedinične serije prvenstvo se odnosi na određivanje veličine jedinične serije. Pritom, veličina jedinične serije može se definirati kao fiksna ili kao promjenjiva vrijednost. Prednost fiksne veličine jedinične serije leži u tome što osigurava jednostavnije vođenje proizvodnje, dok promjenjiva veličina jedinične serije može osigurati pronalazak bolje varijante za zadovoljenje neke od mjera uspješnosti.

Utjecaj veličine jedinične serije može se promatrati kroz prizmu vremena i kroz prizmu troška (Ramya i sur., 2019.). Promatrajući kroz prizmu vremena, veličina jedinične serije direktno utječe na ciklus izrade i ukupna pripremno-završna vremena. Za istu proizvodnu količinu, velike jedinične serije produžuju ciklus izrade, ali smanjuju ukupna pripremno-završna vremena, za razliku od malih jediničnih serija gdje se ciklus izrade smanjuje, a povećava ukupno pripremno-završno vrijeme (Ištoković i sur., 2019.a). Sa stajališta troška, veličina jedinične serije ima direktan utjecaj na troškove pripreme i raspoređivanja radnog mjesta te troškove zaliha. Proizvodnja koja se odvija u velikim jediničnim serijama rezultirat će povećanjem troškova zaliha, ali i smanjenjem troškova pripreme i raspoređivanja radnog mjesta. S druge strane,

kod proizvodnje u manjim jediničnim serijama niži su troškovi zaliha i viši troškovi pripreme i raspoređivanja radnog mjesta (Drexel i Kimms, 1997.).

Prema podacima preuzetim iz baze podataka Web of Science Core Collection, relativno je mali broj radova koji su se bavili zajedničkim problemom planiranja redoslijeda i planiranja veličine jediničnih serija proizvoda, točnije 287 radova. Ako se tome nadoda uvjet proizvodnog okruženja u vidu višepredmetnog linijskog proizvodnog sustava, svega jedanaest radova se bavilo tim problemom.

Za probleme planiranja redoslijeda i planiranja veličine jediničnih serija proizvoda, autori se oslanjaju na matematičke tehnike i heurističke metode koje raspodjeljuju resurse (npr. strojevi, transportna sredstva, radno osoblje i drugi) na radne zadatke koje treba obaviti (Zhang i sur., 2016., Modrak i Soltysova, 2020.). Pritom procjenjujući različite mjere uspješnosti (Chowdhury i sur., 2018., Novas, 2019.): završetak proizvodnje, ciklus izrade, rokovi isporuke, iskoristivost proizvodne opreme, trošak pripreme i raspoređivanja radnog mjesta, trošak proizvodnje, i drugi. Najčešće upotrebljena mjera uspješnosti je ciklus izrade (Hendizadeh i sur., 2007., Lin i Ying, 2012.). Međutim, gledajući sa stajališta proizvodnje u realnom sektoru, postavlja se pitanje koliko je takav scenarij isplativ. Preranim završetkom obrade proizvodi će morati provesti više vremena čekajući na isporuku, za što je potrebno osigurati adekvatno zbrinjavanje tih proizvoda, a to direktno utječe na troškove proizvodnje (Beemsterboer i sur., 2017.).

Smanjenje troškova u proizvodnji jedna je od mjera uspješnosti koja se relativno često procjenjuje u znanstvenoj literaturi. Između ostalih, troškom pripreme i raspoređivanja radnog mjesta su se bavili Li i Milne (2014.), te Stawowy i Duda (2017.). Problemom planiranja redoslijeda i veličine jedinične serije u jednostrojnog okruženju s uključenim troškovima za kašnjenje isporuke bavili su se Ahmadizar i Farhadi (2015.). Yin i sur. (2013.) su razmatrali problem planiranja redoslijeda s ciljem smanjenja ukupnih troškova. Ukupne troškove koji uključuju troškove proizvodnje, isporuke i zaliha u jednostrojnog okruženju su razmatrali Cheng i sur. (2017.). Trigos i Lopez (2016.) su predložili izračun maksimalne dobiti za proizvodnju više različitih vrsta proizvoda u jednostrojnog okruženju uključujući pripremno-završno vrijeme ovisno o slijedu proizvoda.

Nadalje, za optimizaciju mjera uspješnosti koriste se razni optimizacijski alati, poput simuliranog kaljenja (engl. *Simulated Annealing*, SA), umjetnih neuronskih mreža (engl. *Artificial Neural Network*, ANN), optimizacije mravljeg roja (engl. *Ant Colony Optimization*,

ACO), genetskih algoritama (engl. *Genetic Algorithms*, GA) i drugih. Ipak, najčešće korišteni optimizacijski alat su GA, tehnika pretraživanja nadahnuta principom prirodne evolucije i selekcije. Razlog je u tome što su primjenjivi na različite vrste problema, a da pritom pronalaze zadovoljavajuća rješenja (Cavalieri i Gaiardelli, 1998.).

Međutim, probleme iz realnog okruženja vrlo je teško riješiti korištenjem samo optimizacijskih alata, jer brzina konvergencije i učinkovitost algoritama obično je spora za složene optimizacijske probleme (Zhang i sur., 2019.).

S druge pak strane, jedna od najčešće korištenih tehnika za analizu proizvodnih sustava je simulacija diskretnih događaja (engl. *Discrete Event Simulation*, DES). Razlog leži u tome što omogućava izradu digitalnog modela stvarnog proizvodnog sustava te jednostavne naknadne izmjene bez ometanja rada stvarnog sustava. Također, može se koristiti za procjenu i određivanje različitih alternativa proizvodnih konfiguracija i operativnih strategija (Negahban i Smith, 2014.). Bitna prednost DES-a je što može uzeti u obzir nesigurnosti koje su karakteristične za stvarne sustave (npr. kvar na stroju, čekanja, škart i slično). Na taj način je moguće procijeniti mnoge pokazatelje uspješnosti. Zbog svoje velike fleksibilnosti, DES se široko primjenjivao u projektiranju i radu proizvodnih sustava (Gajsek i sur., 2019., Yang i sur., 2020.). Međutim, ako se koristi zasebno, DES nije u mogućnosti pomoći u pronalaženju optimalnih rješenja (Montevecchi i sur., 2012.).

Povezivanje simulacijskih metoda s optimizacijskim alatima prepoznato je kao obećavajuće rješenje. Stoga se u novijoj literaturi može pronaći nekoliko istraživanja koje kombiniraju simulaciju i optimizaciju za rješavanje složenih problema. Za optimizaciju proizvodnih performansi sve češće se koristi programski paket Tecnomatix Plant Simulation koji uz moćnu simulacijsku logiku nudi i mogućnost kombiniranja s nekim optimizacijskim alatima. Pekarcikova i sur. (2020.) su u svom radu predložili uvođenje Kanban logike u kontrolu protoka materijala kako bi poboljšali produktivnost, iskoristivost strojeva i vrijeme obrade. Shi i sur. (2021.) koriste Tecnomatix Plant Simulation za optimiranje završetka proizvodnje, ukupne potrošnje energije i ukupne emisije ugljika za njihov matematički model izrađen na temelju održivog VLPS-a i dinamičke jedinice određivanja redoslijeda. Isti programski paket upotrijebili su Shibin i sur. (2016.) za studiju slučaja proizvodnje automobila fokusirajući se na smanjenje potrošnje energije. Autori Dong i Medeiros (2012.) u svom radu koriste istoimeni programski paket za minimiziranje ukupnog troška proizvodnje u sustavu s jednom fazom

proizvodnje. Ukupni trošak proizvodnje su promatrali kao sumu troškova skladištenja, troškova pripreme i raspoređivanja te troškova zakašnjenja isporuke.

Iz opusa istraženih radova može se zaključiti da u ovom području još uvijek ima mnogo prostora za napredak. U radovima su korištena mnoga pojednostavljena te zanemareni brojni važni čimbenici koji utječu na odvijanje proizvodnog procesa kao i na dobivene rezultate, što dovodi u pitanje koliko ih je primjenjivo u realnom okruženju.

1.3. Svrha i cilj istraživanja

Istražena literatura te činjenica da su današnji zahtjevi tržišta promjenjivi, a kompleksnost i različitost varijanti proizvoda sve veći, dovodi do spoznaje da je detaljno planiranje proizvodnje izrazito važno za uspješno poslovanje proizvodnih poduzeća, pogotovo onih industrijskog tipa. Detaljno planiranje proizvodnje prvenstveno se odnosi na određivanje veličine jediničnih serija i redoslijeda ulaska jediničnih serija proizvoda u sustav što je u uskoj korelaciji s vremenskim iskorištenjem proizvodnog sustava. U tom smislu, određivanje optimalnog vremenskog iskorištenja uz zadovoljenje uvjeta isporuke na vrijeme te što jednostavnije vođenje i praćenje proizvodnog procesa, predstavlja *svrhu istraživanja*.

Stoga, *cilj istraživanja* je analizom postojećih teorijskih i praktičnih znanja i rješenja, razviti simulacijski okvir koji će služiti kao potpora za rješavanje problema planiranja redoslijeda i planiranja veličine jediničnih serija proizvoda. Pritom, razvijenim simulacijskim okvirom osiguralo bi se dobivanje optimalnih vrijednosti veličine jediničnih serija proizvoda i redoslijeda ulaska jediničnih serija proizvoda u sustav, a samim time i optimalnog vremenskog iskorištenja VLPS-a. Također, razvijenim simulacijskim okvirom bi se kroz vizualno jasan prikaz omogućilo jednostavnije planiranje i vođenje proizvodnje.

1.4. Hipoteza istraživanja

Slijedom navedenog, formulirana je *radna hipoteza*:

Razvijenim simulacijskim okvirom definirat će se optimalan redoslijed ulaza jediničnih serija proizvoda i optimalna veličina jediničnih serija proizvoda te time dovesti do optimalnog

vremenskog iskorištenja VLPS-a, što će ujedno dovesti i do smanjenja troškova proizvodnje uz pravovremenu isporuku.

Radna hipoteza će se realizirati kroz tri pomoćne hipoteze:

- (1) Razvijenim simulacijskim okvirom definirat će se optimalan redoslijed ulaza jediničnih serija proizvoda i optimalna veličina jediničnih serija proizvoda te time dovesti do najranijeg završetka proizvodnje.
- (2) Razvijenim simulacijskim okvirom definirat će se optimalan redoslijed ulaza jediničnih serija proizvoda i optimalna veličina jediničnih serija proizvoda s ciljem minimiziranja srednje vrijednosti ciklusa izrade i ukupnog pripremno-završnog vremena uz osnovni uvjet pravovremene isporuke, te time dovesti do optimalnog vremenskog iskorištenja VLPS-a.
- (3) Izrađeni matematički model za izračun troškova proizvodnje unutar razvijenog simulacijskog okvira omogućit će određivanje optimalnih vrijednosti veličine jediničnih serija proizvoda i redoslijeda ulaza jediničnih serija proizvoda s ciljem minimiziranja troškova proizvodnje uz osnovni uvjet pravovremene isporuke, te time dovesti do optimalnog vremenskog iskorištenja VLPS-a.

1.5. Metodologija istraživanja

Na početku istraživanja uvodi se klasifikacija problema planiranja redoslijeda i planiranja veličine jediničnih serija proizvoda. Prema toj klasifikaciji i na osnovi prikupljenih podataka od strane proizvodnog poduzeća iz realnog okruženja, formirat će se konceptualni model VLPS-a. Metodom analize istražiti će se međusobni utjecaj čimbenika unutar proizvodnog sustava te definirati njihove relacije.

Implementiranjem matematičkog modela u definirani računalom potpomognuti model VLPS-a stvorit će se podloga za razvoj znanstveno zasnovane metode. Tako razvijeni simulacijski model će omogućiti eksperimentiranje s računalnim modelom fizikalnog sustava. Kako bi se ostvario cilj potrebno je razviti metodu baziranu na primjeni genetskog algoritma kao optimizacijskog alata. Kombinacijom simulacijske metode i metode optimizacije, odnosno simulacije diskretnih događaja i genetskog algoritma predstaviti će se simulacijski okvir za određivanje optimalnog vremenskog iskorištenja VLPS-a.

1.6. Struktura doktorske disertacije

Doktorska disertacija se sastoji od sedam međusobno povezanih cjelina, a koncipirana je na sljedeći način. U prvom dijelu, UVODU, opisan je problem istraživanja te je dan pregled dosadašnjih istraživanja u području planiranja redoslijeda i planiranja veličina jediničnih serija proizvoda. Definirani su cilj i svrha istraživanja te je postavljena radna hipoteza. Na kraju poglavlja navedene su znanstvene metode koje se koriste u ovom znanstvenom radu.

Drugi i treći dio sadrže pregled znanstvene literature. U drugom dijelu, pod naslovom PLANIRANJE REDOSLIJEDA I VELIČINE JEDINIČNIH SERIJA VLPS-A opisana je pozadina problema pri planiranju proizvodnje s naglaskom na terminiranje proizvodnje. Uvedena je klasifikacija za probleme planiranja redoslijeda i veličine jediničnih serija proizvoda. Isto tako, objašnjene su glavne značajke VLPS-a te su identificirani glavni čimbenici koje treba uključiti za potrebe rješavanja problema terminiranja.

Treći dio, naziva METODE OPTIMIZACIJE I SIMULACIJE, ukratko objašnjava značaj simulacijskih metoda s naglaskom na simulaciju diskretnih događaja. Definirane su prednosti i nedostaci simulacijskih metoda te je objašnjena njihova primjena na industrijska okruženja. Također, u ovom poglavlju objašnjen je optimizacijski alat, genetski algoritam, kroz način njegova rada i kroz ograničenja koja sa sobom nosi.

OPTIMALNO VREMENSKO ISKORIŠTENJE VLPS-A naslov je četvrtog dijela u kojem su detaljno opisane komponente proizvodnog procesa, točnije utroška korištenih proizvodnih resursa na osnovi kojih je izrađen matematički model za izračun troškova proizvodnje. Time je predložena i postavljena nova formulacija troškova proizvodnje.

Petim dijelom, pod naslovom SIMULACIJSKI OKVIR objašnjava se struktura i princip rada simulacijsko-optimizacijskog pristupa za rješavanje problema planiranja redoslijeda i planiranja veličine jediničnih serija proizvoda. Zatim, detaljno se opisuje projektiranje i modeliranje simulacijskog okvira kao kombinacije simulacije diskretnih događaja i implementiranog optimizacijskog alata.

Kako bi se dokazala ispravnost predloženog simulacijskog okvira za određivanje optimalnoga vremenskog iskorištenja, u ovom je radu napravljena cjelovita studija slučaja na primjeru industrijskog proizvodnog poduzeća iz realnog okruženja. Ista je predstavljena u šestom dijelu,

naziva STUDIJA SLUČAJA I REZULTATI EKSPERIMENTALNIH ISTRAŽIVANJA. Također, u tom poglavlju su predstavljeni rezultati primjene simulacijskog okvira za određivanje optimalnog vremenskog iskorištenja VLPS-a pri rješavanju problema planiranja redoslijeda i veličine jediničnih serija proizvoda na studiji slučaja iz realnog okruženja.

Naposljetku, sedmim i posljednjim dijelom, naziva ZAKLJUČAK, iznesene su završne misli kroz potvrđenu radnu hipotezu i ostvareni znanstveni doprinos. Također, dane su smjernice za buduća istraživanja.

Poglavlje 2: PLANIRANJE REDOSLIJEDA I VELIČINE JEDINIČNIH SERIJA VLPS-A

Planiranje predstavlja izradu planova budućih aktivnosti te koordinaciju i kontrolu organizacije ostvarivanja tih planova (www.enciklopedija.hr). Može se definirati kao određivanje odnosa između događaja prije nego što oni započnu, na temelju iskustava iz prošlosti u kombinaciji sa sadašnjim znanjima, vještinama, metodama i tehnikama usmjerenim prema rješavanju budućih problema. U interakciji s vremenom, planiranjem se predviđaju sve aktivnosti, resursi i radno osoblje nužno za obavljanje određenog zadatka.

Nužnost planiranja proizlazi iz sve veće složenosti procesa gospodarskog i društvenog života (Xu i sur., 2018.). Rastom složenosti i obima zadataka, potreba za planiranjem je sve izraženija. Planiranje obuhvaća čitav niz međusobno ovisnih varijabli, stoga je izrazito važno detaljno planiranje svih aktivnosti:


- tko/što i kada će ih izvoditi,
- gdje i s kojim materijalnim resursima (proizvodna oprema, materijal, energija, ...),
- koliko će vremenski trajati aktivnosti.

Mjesto gdje će se zadaci izvoditi, tko će ih obavljati i uz koje tehnološke procese definira se organizacijskom strukturom proizvodnog procesa, a planiranjem se određuje količina proizvoda te odgovarajući vremenski tok za izvršenje zadataka (Mikac i Ikonić, 2013.). Prema

Rossit i sur. (2018.), planiranje je ključno pitanje u procesu poslovanja te je presudno za poboljšanje performansi proizvodnje.

Osnovni zadatak planiranja proizvodnje je osigurati potrebnu kvalitetu proizvoda, uz što manje troškove proizvodnje i pravovremenu isporuku (Wiendahl i sur., 2015.). Pod osiguranjem potrebne kvalitete se podrazumijeva da proizvod bude dovoljno kvalitetan, tj. onoliko koliko je potrebno da zadovolji svoju funkciju. Prevelika kvaliteta podrazumijeva potrebu za većom količinom aktivnosti što za posljedicu ima osim povećanja vrijednosti proizvoda i povećanje mogućnosti kašnjenja isporuke, a to u konačnici dovodi do povećanja troškova proizvodnje. Preveliki troškovi i kašnjenja isporuke dovode u pitanje egzistenciju i konkurentnost proizvodnih poduzeća. Sva tri navedena faktora su usko povezana i direktno utječu jedan na drugog.

Prilikom planiranja proizvodnje donose se mnoge odluke. Prema Ramya i sur. (2019.) te se odluke mogu podijeliti u tri kategorije (slika 2.1): dugoročno planiranje, srednjoročno planiranje, kratkoročno planiranje.



Slika 2.1. Osnovne kategorije planiranja proizvodnje: dugoročno planiranje, srednjoročno planiranje i kratkoročno planiranje

Dugoročno planiranje obično se odnosi na donošenje strateških odluka koje uključuju što i zašto će se proizvoditi, kojim proizvodnim postupcima će se obraditi, gdje će se proizvoditi te koji proizvodni resursi su potrebni za nesmetano odvijanje proizvodnje.

Srednjoročno planiranje uključuje odluke vezane za količinu proizvoda koja će se proizvoditi, odluke o veličini jediničnih serija proizvoda i planiranja materijalnih potreba (engl. *Material Requirements Planning*, MRP). Pritom se optimizira problem veličine jediničnih serija proizvoda minimiziranjem troškova ili maksimiziranjem dobiti, ovisno o ograničenjima proizvodnih kapaciteta i zadovoljenja zahtjeva potražnje.

Kratkoročno planiranje bazira se na odlukama kada će se proizvoditi, poput određivanja redoslijeda ulaska određene jedinice proizvoda ili grupe proizvoda u sustav, određivanja zauzeća pojedine proizvodne opreme, odnosno tko ili što će biti izvršitelj.

Drugi naziv kojim se može poistovjetiti kratkoročno planiranje proizvodnje je operativno planiranje proizvodnje. U području operativnog planiranja proizvodnje postoji niz zadataka ili postupaka koje je potrebno izvršiti kako bi se mogao realizirati proizvodni proces. Za provedbu zadataka odgovorna je operativna priprema koja za cilj ima predvidjeti i planirati sve radnje kako bi se proizvod isporučio na vrijeme. Osnovni zadatak operativnog planiranja je izrada terminskih planova proizvodnje kojima se definira što, kada i koliko treba proizvesti u nekom proizvodnom sustavu (tvornica, postrojenje, radionica, pojedinačni proizvodni kapacitet) za određeno vremensko razdoblje. Terminske planove proizvodnje potrebno je uskladiti s potrebama i mogućnostima proizvodnih resursa: repromaterijala, proizvodnih kapaciteta, radnog osoblja. Prema autoru (Osmanagić-Bedenik, 2012.) oblikovan je skup zadataka koji najbolje opisuju strukturu operativnog planiranja.

- 1) Planiranje sirovina i materijala - prilikom nabave sirovina i materijala potrebno je osigurati dovoljne količine za nesmetano odvijanje proizvodnje. Premala naručena količina ne osigurava nesmetano odvijanje proizvodnje. Prevelika naručena količina uzrokuje stvaranje nepotrebnih zaliha koje uzrokuju povećanje troškova.
- 2) Planiranje rada - podrazumijeva planiranje radne snage. Pritom je potrebno voditi računa o stupnju kvalificiranosti radne snage i normativu utroška rada. Također, važno je osigurati određene radne uvjete, poput temperature radnog mjesta, razine buke, i slično.

- 3) Planiranje alata - kako bi se započelo s proizvodnjom potrebno je osigurati određena pomoćna sredstva, u vidu potrebnih alata, radnih naprava/steznih pribora i mjernih uređaja.
- 4) Planiranje proizvodnih kapaciteta - predstavlja maksimalnu količinu proizvoda koju proizvodni sustav može proizvesti.
- 5) Terminiranje proizvodnje - odnosi se na ispunjenje rokova isporuke, odnosno određivanja početka i završetka pojedinih aktivnosti
- 6) Planiranje redoslijeda - bavi se raspodjelom ograničenih resursa na radne zadatke tijekom određenog vremenskog razdoblja za proizvodnju jednog ili više proizvoda.
- 7) Izrada i lansiranje radne dokumentacije - za potrebu odvijanja nesmetane proizvodnje potrebne su određene informacije koje su pohranjene u raznoj dokumentaciji
- 8) Evidencija izvršenja rokova i količina - završetkom proizvodnog procesa potrebno je evidentirati proizvedene količine i ostvarene rokove

2.1. Terminiranje proizvodnje

Terminiranje predstavlja postupak donošenja odluka kojima se određuje početak i završetak određenih faza proizvodnje te pojedinih proizvodnih aktivnosti i operacija. Provodi se prije početka proizvodnje. Redovito se koristi u mnogim proizvodnim, logističkim i uslužnim djelatnostima s ciljem optimiranja jedne ili više mjera uspješnosti. Liu i sur. (2011.) terminiranje definiraju kao pitanje pronalaženja plana izdavanja radnih zadataka za planirano razdoblje s ciljem maksimiziranja dobiti. Prema autorima (Mikac i Ikonić, 2013.) terminiranje se može podijeliti u dvije skupine:

- terminiranje proizvoda i
- terminiranje operacija.


Terminiranje proizvoda podrazumijeva određivanje termina (rokovi) početka i završetka bilo kojih dijelova ili sklopova finalnih proizvoda za određeno vremensko razdoblje. Glavna zadaća ove aktivnosti je planiranje dinamike izrade proizvoda te provjera plana potreba za materijalima. Terminiranjem operacija određuju se vremena početka i završetka pojedinih operacija u okviru izrade pojedinog proizvoda. Ciljevi terminiranja su ostvarenje ravnomjernog opterećenja radnih mjesta, smanjenje međuoperacijskih zastoja i izvršavanje planskog ciklusa proizvodnje.

U terminologiji terminiranja potrebno je razlikovati tri izraza: niz, redoslijed i pravila raspoređivanja. Niz obično odgovara permutaciji n radnih zadataka ili slijedu radnih zadataka na određenom proizvodnom kapacitetu. Redoslijed se obično odnosi na raspodjelu radnih zadataka u složenijim proizvodnim okruženjima, omogućavajući eventualni prekid obrade radnih zadataka koji su predviđeni za kasniju isporuku. Koncept pravila raspoređivanja koristi se u stohastičkim proizvodnim okruženjima, gdje pravila raspoređivanja propisuju odgovarajuću aktivnost za bilo koje stanje u kojem se sustav može nalaziti. U determinističkim modelima obično se koriste samo nizovi i redosljedi (Pinedo, 2016.).

Uloga terminiranja u nekom općem proizvodnom okruženju može se promatrati na sljedeći način. Zaprimiteljne narudžbe u proizvodnom okruženju potrebno je provesti u određene aktivnosti ili radne zadatke s pripadajućim rokovima isporuke. Ove aktivnosti često predstavljaju obradu na proizvodnim kapacitetima unutar radnih stanica određenim slijedom odnosno prema nekom rasporedu. Obrada tih aktivnosti može se ponekad odgoditi ukoliko su određeni proizvodni kapaciteti zauzeti. Također, velik utjecaj na raspored ima pojava nepredviđenih događaja u proizvodnom pogonu, poput kvarova na strojevima ili vremena obrade dužeg od očekivanog i sličnog. U takvom okruženju razvoj detaljnog planiranja proizvodnih zadataka pomaže u održavanju učinkovitosti i kontrole operacija. Prostor u kojem se odvija proizvodnja ili montaža, bilo automatiziranim sustavom, uz pomoć radnika ili kombinirano, naziva se proizvodni pogon. Proizvodni pogon nije jedini dio organizacije koji utječe na proces terminiranja. Na njega utječe i proces planiranja proizvodnje koji uključuje srednjoročno i dugoročno planiranje za cijelu organizaciju. Terminiranjem se pokušava optimirati cjelokupna proizvodnja i dugoročna raspodjela resursa na temelju nivoa zaliha, predviđanja potražnje i potrebe za resursima. Odluke donesene na višim razinama mogu direktno utjecati na proces terminiranja. Slikom 2.2. prikazan je dijagram toka informacija u proizvodnom sustavu.

U proizvodnom okruženju funkcija terminiranja mora biti u interakciji s drugim funkcijama donošenja odluka. Jedan od popularnih sustava koji se široko koristi je MRP sustav. Nakon generiranja rasporeda potrebno je da su svi materijali (sirovine) i resursi dostupni u određeno vrijeme. Datumi početka obrade svih radnih zadataka moraju se zajednički odrediti sustavom planiranja odnosno terminiranja proizvodnje i MRP sustavom. MRP sustavi su obično prilično složeni. Svaki radni zadatak ima troškovnik (engl. *Bill Of Materials*, BOM) u kojem su navedeni dijelovi koji su potrebni za proizvodnju. MRP sustav prati svaki dio. Nadalje, utvrđuje

vremenski okvir kupnje svakog materijala. Pri tome koristi tehnike kao što su određivanje veličine i redoslijeda jediničnih serija slične onima koje se koriste u sustavima terminiranja. Na raspolaganju su mnogi komercijalni MRP programski paketi i, kao rezultat, postoji mnogo proizvodnih pogona s MRP sustavima. U slučajevima kada proizvodni pogon nema sustav za terminiranje, MRP sustav može se koristiti za potrebe planiranja proizvodnje (Pinedo, 2016.). Međutim, u složenim proizvodnim pogonima MRP sustavu nije lako detaljno planirati na zadovoljavajući način.




Slika 2.2. Dijagram toka informacija u proizvodnom sustavu (Pinedo, 2016.)

Kako bi odredili redoslijed i veličinu jediničnih serija proizvodna poduzeća se oslanjaju na matematičke tehnike i heurističke metode koje raspodjeljuju raspoložive resurse na aktivnosti koje treba obaviti. Prema autorima (Pinedo, 2016., Framinan i sur., 2014.), resursi i aktivnosti u organizaciji mogu biti u različitim oblicima. Pa tako, resursi mogu biti strojevi u proizvodnom

pogonu, radnici na gradilištu, obrade jedinica u računalnom okruženju, i tako dalje. Aktivnosti mogu biti operacije u procesu proizvodnje, faze građevinskog projekta, izvršenje računalnih programa, i slično. Svaka aktivnost može imati određenu razinu prioriteta, npr. najranije moguće vrijeme početka i rok dospijanja (Pinedo, 2005.).

Osnovna zadaća svih problema terminiranja je predložiti raspored koji poštujući sva operativna, logistička i tehnička ograničenja postiže određeni cilj (Georgiadis i sur., 2019.). Ciljevi mogu biti najraniji završetak proizvodnje ili povećanje iskoristivosti proizvodne opreme. Opći problem terminiranja može se sažeti kroz sljedeća pitanja (slika 2.3.):

- Koje aktivnosti se moraju izvršiti da bi se zadovoljio zadani zahtjev (dijeljenje proizvodnih količina na jedinične serije)?
- Kako i kojim redoslijedom koristiti dane proizvodne resurse (dodjeljivanje jediničnih serija proizvodnim resursima)?



Slika 2.3. Odluke o planiranju rasporeda proizvodnje u proizvodnim poduzećima (Georgiadis i sur., 2019.)

Pritom treba imati na umu da je prilikom razvoja modela za određivanje rasporeda odvijanja aktivnosti, važno uzeti u obzir sve karakteristike proizvodnje kako bi se osigurala izvedivost predloženih rasporeda. Međutim, proizvodnju treba prikazati apstraktno kako bi se smanjila računska složenost problema. To je još važnije kada se radi o stvarnim proizvodnim poduzećima, koje obično karakteriziraju složene strukture, sve veći asortiman proizvoda i veliki broj ograničenja koja se moraju uzeti u obzir.

2.1.1. Planiranje redoslijeda

Planiranje redoslijeda važna je funkcija u planiranju i kontroli proizvodnje u kojoj se aktivnosti povezane s proizvodnjom projiciraju na vremenskoj skali. Postoje mnoge definicije problema planiranja redoslijeda. Pa tako, Ramya i sur. (2015.) problem planiranja redoslijeda radnih zadataka definiraju kao određivanje redoslijeda ili niza u kojem će strojevi obraditi radne zadatke tako da optimiraju neku od mjera uspješnosti.

Prema Gravesu (1981.), planiranje redoslijeda podrazumijeva pronalaženje onih radnji koje treba napraviti pomoću resursa i opreme, istodobno čineći ustupke između učinka ranije ili kasnije završenog radnog zadatka. Raspored dodjeljuje određeni radni zadatak određenom proizvodnom kapacitetu tijekom vremena i određuje redoslijed radnih zadataka na temelju kriterija odlučivanja, kao što su završetak proizvodnje, rokovi isporuke ili minimalni ciklus izrade (Pardalos i sur., 2013.).

Postoje dva načina planiranja redoslijeda: planiranje redoslijeda unaprijed i planiranje redoslijeda unatrag. Kod planiranja redoslijeda unaprijed, radni zadaci se planiranju od datuma kada proizvodni resursi postanu dostupni kako bi se odredio datum otpreme ili rok dospijeca. Planiranje redoslijeda unatrag podrazumijeva planiranje radnih zadataka od datuma otpreme ili roka dospijeca kako bi se odredio datum početka i/ili bilo koje promjene u potrebnim kapacitetima.

Planiranje redoslijeda uglavnom se predstavlja kao problem optimizacije u literaturi. Pa tako, Yu i sur. (2011.) predstavljaju nelinearni višekriterijski programski model za planiranje redoslijeda u preradi minerala. Wang i sur. (2009.) su predložili okvir za podršku optimizaciji planiranja redoslijeda integrirajući sustav za planiranje resursa poduzeća (engl. *Enterprise Resource Planning*, ERP) kao informacijski sustav.

2.1.2. Planiranje jediničnih serija

Velika većina znanstvenih radova bavi se problemima terminiranja radnih naloga gdje se svaki radni nalog promatra kao jedan posao, jedan zadatak. Međutim, ukoliko se jedan radni nalog sastoji od relativno velike količine proizvoda koju treba proizvesti, a istu nije moguće proizvesti odjednom, tada je ukupnu količinu proizvoda potrebno podijeliti na manje količine odnosno na jedinične serije proizvoda.

Pojam veličina jedinične serije proizvoda (lota) zapravo podrazumijeva određenu količinu proizvoda koja čini jedan radni zadatak tj. kod koje se pojedina operacija izvodi na svim jedinicama proizvoda u vremenski vezanoj proizvodnji uz jednokratni trošak pripreme i raspoređivanja radnog mjesta. Jedinična serija proizvoda u stvari predstavlja samo onaj dio ukupne količine proizvoda iste konstrukcijske izvedbe koji ulazi u proces u određenom vremenskom trenutku i prolazi kroz proces kao jedna cjelina. Pritom vrijedi pravilo da se jedna cjelina može premjestiti na sljedeće radno mjesto (sljedeću operaciju) tek nakon što i posljednja jedinica proizvoda iz te cjeline bude obrađena na tom radnom mjestu.

Veličina jedinične serije proizvoda može biti fiksna ili promjenjiva. Promjenjiva veličina jedinične serije omogućava različite vrijednosti za svaku jediničnu seriju proizvoda. Pritom svaka jedinična serija proizvoda može poprimiti vrijednost u rasponu od samo jednog proizvoda pa sve do $q - b$ proizvoda, gdje q predstavlja ukupnu količinu proizvoda a b broj jediničnih serija proizvoda. Takvom, promjenjivom veličinom serije proizvoda može se osigurati minimiziranje ciklusa izrade (Perinić i sur., 2008.), kao i najranije vrijeme završetka svih radnih zadataka (Chen i Song, 2009.).

Kako raspon veličina jediničnih serija može drastično varirati, ono može predstavljati veliki problem pri upravljanju i vođenju proizvodnje. Imajući na umu složenost i dimenzije proizvoda, velike razlike u veličini jediničnih serija može zahtijevati različite vrste transportnih sredstava, povećanje međuskladišnih prostora i slično. U konačnici, zbog navedenih razloga promjenjiva veličina jediničnih serija vrlo lako može biti nepovoljna za primjenu u stvarnoj proizvodnji.

S druge strane, fiksna veličina jedinične serije predstavlja konstantan broj jedinica proizvoda od kojih se sastoji svaka jedinična serija proizvoda. Na taj način osigurava se jednostavnije upravljanje i vođenje proizvodnjom, što je često u korelaciji sa smanjenim troškovima proizvodnje. Fiksnom veličinom jedinične serije proizvoda također se može minimizirati ciklus izrade proizvoda (Brajković, 2018.), ali uvjetuje da ukupna količina proizvoda mora biti višekratnik vrijednosti fiksne veličine jedinične serije.

U realnom sektoru ukupna proizvodna količina proizvoda može biti bilo koja vrijednost tako da se pojavljuje problem ako ta vrijednost nije višekratnik veličine jedinične serije, tj. pojavljuje se ostatak, što dovodi do potrebe za pronalaskom kompromisa za ove dvije vrste veličina jediničnih serija kako bi se iskoristile njihove prednosti.

Iako u manjem obimu u odnosu na planiranje redoslijeda, planiranje jediničnih serija se relativno često obrađuje u znanstvenoj literaturi. Prema Sox i sur. (1999.), problemi s veličinom jediničnih serija mogu se identificirati u dva pravca: uključujući radove koji koriste kontinuirane vremenske modele prepoznate kao ekonomski problem određivanja veličine jediničnih serija i radove koji koriste diskretne vremenske modele identificirane kao količinski problem određivanja veličine jediničnih serija.

2.2. Klasifikacija problema terminiranja proizvodnje

Postoji velik broj aspekata koje je potrebno uzeti u obzir pri razvoju modela za terminiranje serijskih procesa. Sustavnu karakterizaciju tih aspekata, prema autorima (Graves, 1981., Mendez i sur., 2006., Pinedo, 2016.), može se prikazati pomoću 9 glavnih kategorija koje razmatraju ne samo opremu i materijalne probleme nego i ograničenja vezana za vrijeme i potražnju. Takva klasifikacija za razvrstavanje najrelevantnijih značajki problema terminiranja kod postrojenja sa serijskim tipom proizvodnje je sljedeća:

1. Izgled sustava

- | | |
|---------------------------------|---|
| a) prema izradi zahtjeva | - zatvoreni tip
- otvoreni tip |
| b) složenost obrade | - sustav s jednom fazom (jedan ili više strojeva)
- sustav s više faza |
| c) smjer kretanja proizvoda | - protočni (prolazni)
- povratni |
| d) dodjela proizvodne opreme | - fiksna
- promjenjiva (varijabilna) |
| e) povezanost proizvodne opreme | - potpuna
- ograničena (parcijalna) |

2. Pravila o zalihama

- | | |
|-----------------------------------|---|
| a) politika međuskladištenja | - neograničen kapacitet
- ograničen kapacitet
- bez čekanja |
| b) prijenos (transport) proizvoda | - trenutno (zanemaren)
- postojeći (oduzimajući vrijeme) |

- | | |
|------------------------------|---|
| 3. Jedinične serije | - fiksna
- promjenjiva |
| 4. Vremena izrade | |
| a) fiksno | - neovisno
- ovisno (o proizvodu) |
| b) promjenjivo (varijabilno) | - ovisno o veličini serije |
| 5. Obrasci potražnje | |
| a) rokovi dospijeca | - za jedan proizvod
- za više proizvoda |
| b) neovisno terminiranje | - fiksni zahtjevi
- minimalni/maksimalni zahtjevi |
| 6. Ograničenja | |
| a) priprema i raspreda RM | - zanemarena
- ovisna o proizvodnoj jedinici
- ovisna o slijedu (proizvoda i proizvodne jedinice) |
| b) ograničenja resursa | - bez ograničenja (jedino proizvodna oprema)
- diskretna
- kontinuirana |
| c) vremenska ograničenja | - bez ograničenja
- neravno razdoblje, održavanje, smjene |
| 7. Troškovi | - oprema
- komunalne usluge
- inventar
- priprema i raspreda RM |
| 8. Stupanj nesigurnosti | - deterministički
- stohastički |
| 9. Okruženje | - statičko
- dinamičko |
-

2.2.1. Izgled sustava

Osnovni kriterij za klasifikaciju problema terminiranja je izgled sustava koji se dijeli na sustave otvorenog i zatvorenog tipa. Kod sustava otvorenog tipa aktivnosti se odvijaju prema slijedu radnih naloga, dok kod zatvorenog tipa se moraju razmotriti i problem terminiranja i odluke o veličini jediničnih serija povezane s postupkom dopunjavanja zaliha.

Izgled sustava može se podijeliti s obzirom na složenost obrade na sustave s jednom fazom (radnom stanicom) u kojoj se nalazi jedan ili više identičnih strojeva te sustave s više faza. U protočnom ili linijskom sustavu s više faza, svi radni zadaci zahtijevaju isti redoslijed obrade na istim proizvodnim resursima. Kod povratnog sustava s više faza nema ograničenja kako bi se izvršio određeni radni zadatak. Raspored proizvodnih resursa u proizvodnom sustavu direktno je povezan s ograničenjima u vidu dodjele i povezivanja proizvodne opreme, koji može varirati od potpuno fiksnog do fleksibilnog rasporeda.

2.2.2. Pravila o zalihama

Drugi važan kriterij se odnosi na pravila o zalihama. Međuskladišni kapaciteti između susjednih (uzastopnih) proizvodnih kapaciteta mogu biti gotovo neograničeni. To se često događa kada su proizvodi koji se obrađuju fizički mali, što omogućava relativno jednostavno skladištenje velikih količina između proizvodnih kapaciteta. Ako su proizvodi fizički veliki i glomazni, tada međuskladišni kapacitet može biti ograničen što može uzrokovati zastoje (blokadu). Zastoj se događa kada je međuskladišni prostor pun, a prethodni proizvodni kapacitet ne može otpustiti proizvod nakon njegova završetka, jer ga nema kamo ostaviti. Ako se to dogodi, proizvod mora ostati na prethodnom proizvodnom kapacitetu sve dok se mjesto u međuskladištu ne oslobodi te na taj način sprječava sljedeći proizvod da započne s obradom na tom proizvodnom kapacitetu. Važnu ulogu u tome ima i dostupnost transportne opreme koja je često zanemarena u znanstvenim istraživanjima. Ukoliko transportna oprema nije dostupna za prijenos proizvoda s jednog na drugo radno mjesto pojavljuje se čekanje obrađenih proizvoda u međuskladištu.

2.2.3. Jedinične serije

Velik broj istraživanja ugovorenu proizvodnu količinu ne dijeli, nego svaki radni nalog predstavlja jedan zadatak. Na taj način se onemogućava dijeljenje proizvodnih količina na manje cjeline. Taj nedostatak pogotovo je izražen kod većih količina tehnološki složenih

proizvoda, jer dijeljenje proizvodne količine određenog proizvoda može dovesti do velikih ušteda. Prije svega vremenskih, a samim time, u određenoj mjeri i novčanih ušteda. Manje cjeline, jedinične serije, nastale dijeljenjem proizvodnih količina mogu biti fiksne i promjenjive.

2.2.4. Vremena izrade

Vrijeme izrade predstavlja vremenski period potreban za odvijanje određene aktivnosti na jednom radnom mjestu (RM) kako bi se promijenila kvalitativna svojstva nekog proizvoda. Može se definirati za jednu jedinicu proizvoda ili za grupu proizvoda (jediničnu seriju proizvoda). Ukoliko se definira za jednu jedinicu proizvoda onda vrijeme izrade predstavlja vrijeme operacije. Vrijeme izrade na pojedinom proizvodnom kapacitetu može se definirati kao fiksna ili kao promjenjiva vrijednost. Pritom, fiksna vrijednost može i ne mora ovisiti o različitim vrstama proizvoda koje se obrađuju na tom proizvodnom kapacitetu.

2.2.5. Obrasci potražnje

Obrasci potražnje se mogu okarakterizirati kao ciljevi planiranja te se kao takvi mogu značajno razlikovati, od slučajeva kada se moraju poštivati rokovi isporuke do slučajeva kada se ciljevi proizvodnje moraju ispunjavati u određenom vremenskom razdoblju (fiksni ili minimalni/maksimalni zahtjevi).

2.2.6. Ograničenja

Postoje mnoga ograničenja koja utječu na odvijanje proizvodnog procesa. Promatrajući realnu proizvodnju često se stvaraju ograničenja kao što su neradni dani, neradne smjene i razdoblja održavanja. Ne treba zaboraviti važan aspekt u proizvodnji a to je priprema i rasprega RM koja može biti ovisna o proizvodnom kapacitetu te ovisna o slijedu s obzirom na proizvod. Isto tako, može biti ovisna o slijedu s obzirom na proizvod i proizvodni kapacitet, ali se može i zanemariti.

2.2.7. Troškovi

Dok se terminiranje često smatra problemom izvedivosti, troškovi koji se odnose na upotrebu opreme, zaliha, pripreme i rasprega radnog mjesta i drugih usluga mogu imati značajan utjecaj u određivanju optimalnog rasporeda.

2.2.8. Stupanj nesigurnosti

Proizvodna okruženja u stvarnom svijetu podložna su mnogim izvorima nesigurnosti odnosno slučajnosti. Izvori nesigurnosti koji mogu imati velik utjecaj uključuju primjerice kvar proizvodne opreme ili neočekivanu isporuku visoko prioritetnog posla.

Također, izvor nesigurnosti leži u vremenskom trajanju procesa koje se često ne zna unaprijed. Ako su te slučajnosti zanemarene onda se govori o determinističkom modelu, u suprotnom se govori o stohastičkom modelu. Postoji nekoliko načina na koje se mogu modelirati takvi oblici nesigurnosti. Kvar proizvodnog kapaciteta može se definirati kao dio vremena izrade na način da se u vrijeme izrade uračuna i vjerojatnost pojave kvara i njegovog trajanja. Isto tako, kvar se može modelirati kao zasebni stohastički događaj koji određuje je li proizvodni kapacitet dostupan ili nije.


2.2.9. Okruženje

Naposljetku, posljednji aspekt je vezan za okruženje problema terminiranja, pa se tako razlikuju problem sa statičkim terminiranjem kada su dostupni broj radnih mjesta i njihova vremena te problem s dinamičkim terminiranjem kad se broj poslova i povezane karakteristike mijenjaju s vremenom.

2.3. Višepredmetni linijski proizvodni sustavi

Linijski ili protočni sustavi su vrsta proizvodnih sustava koji se koriste za proizvodnju srednjih ili velikih količina određenog proizvoda (Ištoković i sur., 2019.b). U mnogim pogonima za proizvodnju i montažu svaki proizvod mora proći niz operacija. Pritom se operacije moraju obavljati na svim proizvodima istim redoslijedom, što podrazumijeva da proizvodi moraju slijediti isti put. Uz pretpostavku da su proizvodni kapaciteti serijski postavljeni, proizvodno okruženje se tada naziva linijski ili protočni sustavi (Garey i sur., 1976.). Baker i Trietsch (2009.), predstavljaju linijske proizvodne sustave kao sustave koji se sastoje od najmanje dvije faze proizvodnje, gdje se svaka faza proizvodnje sastoji od samo jednog resursa (stroja). Ovisno o tome da li se proizvodi jedan ili više proizvoda u određenom proizvodnom sustavu, takvi sustavi se mogu klasificirati kao jednopredmetni linijski proizvodni sustav (JLPS) i višepredmetni linijski proizvodni sustav (VLPS).

Promatrajući današnje okruženje, relativno česte promjene na tržištu dovode do potrebe za izradom više tehnološki sličnih proizvoda. Tehnološki slični proizvodi predstavljaju one proizvode koji imaju visok stupanj sličnosti redoslijeda obrade i trajanja operacija (Ištoković i sur., 2019.a). Kako bi se izvršile aktivnosti za proizvodne količine više različitih radnih zadataka (proizvoda), često se pojavljuje potreba za većim brojem strojeva (proizvodnih kapaciteta) u određenim fazama proizvodnje. Takvo proizvodno okruženje koje se sastoji od više faza proizvodnje u nizu s nekoliko paralelnih proizvodnih kapaciteta u nekim fazama i u kojem se obrađuju veće količine sličnih ali ipak različitih radnih zadataka, naziva se višepredmetni linijski proizvodni sustav, slika 2.4.




Slika 2.4. Shema višepredmetnoga linijskoga proizvodnog sustava (Jiang i Zhang, 2019.)

U realnom svijetu, VLPS je preferirani izbor za procesna ili diskretna proizvodna poduzeća za vođenje proizvodnje po narudžbi i masovne prilagodbe. Široko se koristi u mnogim industrijama kao što su proizvodnja strojeva, proizvodnja automobila, proizvodnja elektronike i kemijska proizvodnja (Ribas i sur., 2010.). Primjenjuje se u proizvodnji srednjih i velikih količina više različitih vrsta tehnološki sličnih proizvoda. Karakteristike VLPS-a su sljedeće:

- postoji više od jedne faze u proizvodnom procesu,
- postoji jedan ili više proizvodnih kapaciteta u svakoj od faza proizvodnje,
- radni zadaci odnosno proizvodi se jednosmjerno kreću kroz proizvodni proces,
- svi radni zadaci podliježu prioritetima koji ih ograničavaju na isti redoslijed izrade u svim fazama proizvodnje,
- svaki proizvodni kapacitet može obavljati najviše jednu operaciju bilo kojeg radnog zadatka u istom trenutku,
- operacija određenog radnog zadatka ne može se izvesti sve dok se ne završe prethodne operacije tog radnog zadatka,

- jednom započeta operacija na proizvodnom kapacitetu ne smije se prekidati,
- nema alternativnih usmjeravanja, tj. operaciju nekog radnog zadatka može obavljati samo jedna vrsta proizvodnog kapaciteta,
- nakon završetka izrade ili operacije na jednom proizvodnom kapacitetu radni zadatak se pridružuje redu čekanja na sljedećem proizvodnom kapacitetu,
- ne postoji ograničenje duljine čekanja na bilo kojem proizvodnom kapacitetu.

VLPS, između ostalog, karakterizira i velika produktivnost te mala fleksibilnost, što za posljedicu ima izrazito malo prostora za manipulaciju s vremenom za odvijanje proizvodnje. Iz toga razloga pojavljuje se problem optimiranja takvog sustava, što može potvrditi velik broj radova na tu temu. U novijoj znanstvenoj literaturi proizvodni sustav (PS) s takvim karakteristikama, prema Ribas i sur. (2010.), često se naziva hibridni linijski proizvodni sustav (engl. *Hybrid Flow Shop*, HFS). Ta terminologija, navode isti autori, objedinjuje sve dosadašnje nazive korištene u literaturi, slika 2.5., poput: fleksibilni linijski PS (engl. *Flexible Flow Shop*, FFS), linijski PS s više strojeva (engl. *Flow Shop with Multiple Processors*, FSMP), višestrojni linijski PS (engl. *Multiprocessor Flow Shop*, MFS), i linijski PS s paralelnim strojevima (engl. *Flow Shop with Parallel Machines*, FSPM).



Slika 2.5. Sinonimi korišteni u literaturi za višepredmetni linijski ili protočni proizvodni sustav

2.4. Notacija višepredmetnih linijskih proizvodnih sustava

Oznake koje se koriste prilikom planiranja redoslijeda i planiranja veličine jediničnih serija u VLPS-u, prema Pinedu (2016.) te Ribas i sur. (2010.) mogu se prikazati na sljedeći način. Obično oznaka j se koristi za određeni radni zadatak ili proizvod, dok oznaka i predstavlja operaciju odnosno fazu proizvodnje. Kako posao zahtjeva više od jednog koraka ili više od jedne faze obrade, tada uređeni par i, j se odnosi na operaciju i na proizvodu j . Proizvodni kapacitet (stroj) se najčešće označava s m , a broj proizvoda (radnih zadataka) s n . S proizvodom j su povezani sljedeći podaci:

- vrijeme izrade ili vrijeme operacije, o_{ij} - oznaka o_{ij} predstavlja trajanje operacije odnosno izrade i nekog proizvoda j .
- vrijeme ulaska r_j - oznaka r_j odnosi se na vrijeme u kojem proizvod j ulazi u sustav, tj. najranije vrijeme u kojem proizvod j može započeti s obradom.
- vrijeme isporuke d_j - oznaka d_j odnosi se na rok za završetak j -tog proizvoda, tj. vrijeme kada je obećano isporučiti robu ili uslugu naručionicu. Završetak izrade proizvoda j nakon roka je moguć ali uvjetuje kaznu kroz penale.

Spoznaja da se u VLPS-u proizvode srednje ili velike količine više različitih proizvoda dovodi do potrebe dijeljena proizvodnih količina na jedinične serije proizvoda. Veličina jedinične serije j -tog proizvoda označava se oznakom Lot_j .

2.4.1. Karakteristike i ograničenja izrade

Problem planiranja redoslijeda i planiranja veličine jediničnih serija, prema Pinedu (2005.), može se opisati s tri polja: $\alpha / \beta / \gamma$ (slika 2.6.). Polje α opisuje proizvodno okruženje i može poprimiti samo jedan unos. Polje β sadrži karakteristike i ograničenja izrade te ne mora sadržavati nikakav unos, ali može biti i više od jednog unosa. Cilj kojem se teži opisuje se poljem γ i najčešće sadrži jedan unos.

Postoji nekoliko proizvodnih okruženja, međutim ovo istraživanje je usmjereno na VLPS. Prema tome, navest će se one karakteristike i ograničenja izrade te ciljevi koji su karakteristični za proizvodno okruženje VLPS-a. Karakteristike i ograničenja izrade kod problema planiranja redoslijeda i planiranja veličine jediničnih serija u VLPS-u mogu biti sljedeća:

- Vrijeme ulaska (r_j) - označava da proizvod j ne može započeti izradu prije određenog vremena ulaska (Pinedo, 2016.).
- Prioritetni radni zadatak ($prec$) - može se pojaviti ukoliko jedan ili više radnih zadataka mora biti obrađeno prije nego se dopusti drugom radnom zadatku da započne s izradom. Primjer prioritetskog radnog zadatka se pojavljuje kod dugačkih pripremno-završnih vremena koja ovise o slijedu proizvoda (Conway i sur., 2003.).
- Pripremno-završno vrijeme ovisno o slijedu (pz_{jk}) - ova oznaka podrazumijeva potrebu za pripremom i raspromom radnog mjesta zbog dolaska proizvoda k nakon proizvoda j (Allahverdi, 2015.).
- Familije proizvoda ($fmls$) - proizvodi iz iste familije mogu imati različita vremena operacija, ali se mogu obraditi na istom proizvodnom kapacitetu jedni za drugim bez potrebe za pripremom i raspromom radnog mjesta (Pinedo, 2005.).
- Vrijeme transporta (t_l) - označava da je potrebno određeno vrijeme za premještanje proizvoda (Pinedo, 2005.).
- Kvar proizvodnog kapaciteta (brk) - podrazumijeva da proizvodni kapacitet nije stalno dostupan zbog pojave kvara (Allahverdi, 2015.).
- Zastoj ($block$) - ukoliko se međuskladište između dva uzastopna susjedna proizvodna kapaciteta napunilo, tada dolazi do pojave zastoja, jer prethodni proizvodni kapacitet ne može otpustiti obrađeni proizvod i preuzeti novi, sve dok se ne oslobodi mjesto u međuskladištu (Ramya i sur., 2013.).
- Bez čekanja (nwt) - pojava kada proizvodi između dva uzastopna susjedna proizvodna kapaciteta ne smiju čekati. To podrazumijeva da se početak izrade određenog proizvoda mora odgoditi sve dok se ne osigura prolaz proizvoda kroz proizvodni proces bez zastajanja. Primjer se može pronaći u valjaonici čelika gdje čelična ploča ne smije čekati na obradu, jer bi se u međuvremenu ohladila (Pinedo, 2016.).
- Prerada (rwk) - označava da određeni proizvodi moraju ponovno posjetiti prethodnu fazu proizvodnje zbog problema s kvalitetom (Ribas i sur., 2010.).

2.4.2. Funkcije cilja

Cilj kojem se teži pri planiranju redoslijeda i planiranju veličine jediničnih serija je odrediti najbolji mogući raspored za odvijanje proizvodnje. Raspored se određuje pomoću definirane

funkcije cilja. Funkcija cilja zapravo predstavlja funkciju koja teži određenu vrijednost minimizirati ili maksimizirati.

Prema Pinedo (2005.) ciljevi se mogu razvrstati u tri skupine:

- a) ciljevi propusnosti i završetka proizvodnje,
- b) ciljevi vezani za rokove isporuke,
- c) ciljevi vezani za troškove.

a) U skupinu propusnosti i završetka proizvodnje mogu se uključiti sljedeći ciljevi:

- Završetak proizvodnje (C_{max}) - maksimalno vrijeme završetka posljednjeg radnog zadatka (proizvoda). Nakon što se proizvod j izradi u svim fazama proizvodnje prema rasporedu, on izlazi iz sustava. Vrijeme kada izlazi iz sustava predstavlja vrijeme završetka proizvoda j i označava se s C_j . Maksimalno vrijeme završetka radnog zadatka odnosi se na vrijeme izlaza iz sustava posljednjeg proizvoda j , a definira se kao:

$$\max(C_1, \dots, C_n) \quad (2.1.)$$

Većina istraživanja vezana za problem planiranja redoslijeda i planiranja veličine jediničnih serija za cilj su imala završetak proizvodnje. završetak proizvodnje kao cilj se često koristi u praksi, jer njegovo minimiziranje u određenoj mjeri maksimizira iskorištenje proizvodnih kapaciteta. Međutim, ako su modeli vrlo složeni tada je relativno teško dobiti rezultate. Ukupno vrijeme dovršetka i rokovi isporuke obično su još teže postavljeni ciljevi.

- Propusnost (Th) - cilj je povećati propusnost odnosno broj obavljenih radnih zadataka odnosno izrađenih proizvoda po satu. U istraživanja vezanim za ovo područje često se za cilj postavlja maksimalna propusnost. Maksimalna propusnost se postiže maksimalnim iskorištenjem proizvodnih kapaciteta, posebno onih gdje se nalazi usko grlo.

b) Rok isporuke postaje sve važniji u današnjem konkurentnom okruženju (Vinod i sur., 2017.). Prema Hillu (1995.), postoje dva aspekta performansi rokova isporuke: pouzdanost isporuke i brzina isporuke. Pouzdanost isporuke je sposobnost stalnog ispunjavanja obećanih datuma isporuke. Brzina isporuke predstavlja mogućnost isporuke narudžbe kupaca s kratkim

rokovima isporuke. Philipoom (2000.) navodi da su kupci manje spremni prihvatiti dugoročne isporuke. Prema autorima (Pinedo, 2005., Ribas i sur., 2014., Frantzen, 2013.) ciljevi povezani sa datumom dospijeca prikazani su kako slijedi:

- Maksimalno kašnjenje (K_{max}). Cilj je smanjiti kašnjenje zadnjeg radnog zadatka odnosno onog proizvoda j koji je imao najveće kašnjenje. Kašnjenje proizvoda j može se definirati kao:

$$K_j = C_j - d_j \quad (2.2.)$$

- Kašnjenje može poprimiti vrijednost manju od nule što podrazumijeva završetak prije roka, a s time se često ništa ne dobije. Stoga je prikladnije raditi sa zakašnjenjem (vidi Baker i Trietsch, 2009.). Maksimalno kašnjenje određuje se kao:

$$K_{max} = \max(K_1, \dots, K_n) \quad (2.3.)$$

- Maksimalno zakašnjenje (Z_{max}). Slično kao kod maksimalnog kašnjenja, cilj je smanjiti zakašnjelost zadnjeg radnog zadatka, odnosno proizvoda j s najvećim zakašnjenjem. Zakašnjenje proizvoda j određuje se prema izrazu:

$$Z_j = \max(C_j - d_j, 0) = \max(K_j, 0) \quad (2.4.)$$

- Zakašnjenje proizvoda j može biti nula (na vrijeme) ili veće od nule (zakašnjelost). Razlika između kašnjenja i zakašnjelosti je u tome što zakašnjelost ne može biti negativna (T'Kindt i sur., 2002.).
- Ukupna zakašnjelost (Z_{uk}). Cilj je smanjiti ukupno zakašnjenje svih zakašnjelih radnih zadataka. Izračunava se kao suma svih zakašnjelih radnih zadataka.

$$Z_{uk} = \sum (Z_1 + \dots + Z_n) \quad (2.5.)$$

- Broj radnih zadataka nakon roka dospijeca (U). Cilj je smanjiti ukupan broj radnih zadataka nakon roka dospijeca.
- Prosječna zakašnjelost ($\bar{Z}$). Cilj je smanjiti prosječnu zakašnjelost svih radnih zadataka. Određuje se kao srednja vrijednost svih zakašnjelosti. Definira se prema izrazu:

$$\bar{Z} = \frac{Z_{uk}}{U} \quad (2.6.)$$

- Maksimalna prijevremenost (R_{max}). Cilj je smanjiti završetak najranijeg radnog zadatka. Pojavljuje se iz razloga kako bi radni zadaci (proizvodi) što kraće vrijeme provodili kao zaliha čekajući na isporuku, jer na taj način stvaraju dodatni trošak (Demir i sur., 2015.). Vrijeme preranog završetka proizvoda j ne može poprimiti negativnu vrijednost, a određuje se kako slijedi:

$$R_j = \max(d_j - C_j, 0) \quad (2.7.)$$

- U literaturi se također mogu pronaći istraživanja koja kombiniraju ukupnu prijevremenost i ukupnu zakašnjelost kako bi optimirali završetak obrade najbliže moguće roku isporuke.

c) Primjeri ciljeva koji se odnose na troškove su (Frantzen, 2013.):

- troškovi pripreme i raspreme T_{PZ} ,
- troškovi zaliha u radu T_{WIP} ,
- troškovi zaliha gotovih proizvoda T_{GP} ,
- troškovi transporta T_T .

Isto tako, postoje i drugi troškovi koji su rješavani u literaturi. Između ostalih, Dai i sur. (2013.) rješavali su problem planiranja redoslijeda s ciljem smanjenja ukupne potrošnje energije VLPS-a, koristeći poboljšani genetski simulirani algoritam kaljenja. Zhang i sur. (2014.) su uvrstili minimalni ukupni trošak električne energije i minimalnu stopu emisije ugljika u višekriterijsku funkciju cilja za rješavanje problema planiranja redoslijeda linijskog sustava. Schulz i sur. (2019.) razmatrali su minimiziranje zaliha, ukupnih troškova energije i najvećeg opterećenja kao ciljnih funkcija za rješavanje problema energetskog planiranja VLPS-a.

2.4.3. Okruženje VLPS-a

Problemi planiranja redoslijeda i planiranja veličine jediničnih serija su najteži kombinatorni problemi optimiranja. Ranija istraživanja u ovom području su koncentrirana na determinističke probleme, odnosno one probleme u kojima su unaprijed poznate sve numeričke veličine, poput vremena izrade (operacija), rokova isporuke i slično. Međutim, u posljednjih desetak godina sve više istraživanja se bavi problemom neizvjesnosti. Takvi problemi nazivaju se stohastičkim problemima, gdje je barem jedna varijabla slučajna tj. nije poznata unaprijed. Vrijeme izrade

se pretpostavljalo kao glavni izvor nesigurnosti (Balasubramanian i Grossmann, 2003.). Također, stohastička optimizacija vrlo je čest pristup u literaturi o planiranju redoslijeda i planiranju veličine jediničnih serija u sklopu nesigurnosti (Hamta i sur., 2014., Rauf i sur., 2020.).

Osim toga, problemi se mogu podijeliti na statičke i dinamičke. Statički problem pretpostavlja da su svi radni zadaci dostupni u nultom vremenu, za razliku od dinamičkog problema gdje svi radni zadaci nisu dostupni u nultom vremenu.

Poglavlje 3: METODE OPTIMIZACIJE I SIMULACIJE

Prema klasičnoj definiciji problema planiranja redoslijeda, cilj je pronaći najbolji mogući raspored odnosno sekvencu gdje se određeni proizvodni resursi dodjeljuju određenim poslovima kroz određeni vremenski period koji se promatra. Ovisno o postavljenim ciljevima i ograničenjima, rezultat svakog problema planiranja redoslijeda je raspored koji izravno utječe na vremensko iskorištenje promatranog proizvodnog sustava.

Za pronalazak najboljeg, tj. optimalnog rasporeda do sada su korištene brojne tehnike i metode. Pronalazak optimalnog rasporeda prije svega ovisi o složenosti problema rješavanja, a to dovodi u pitanje učinkovitost tehnika i metoda optimizacije. Pogotovo za rješavanje složenih problema iz realnog okruženja.

3.1. Metode rješavanja problema planiranja redoslijeda i veličine jediničnih serija

Metodologija koja se koristi za rješavanje problema planiranja redoslijeda i veličine jediničnih serija razlikovat će se ovisno o kakvom se problemu radi i prema zahtjevima rješenja (Frantzen, 2013.). Prema Esmaeilian i sur. (2016.) za rješavanje problema planiranja redoslijeda i veličine

jediničnih serija ponuđena je široka paleta tehnika i metoda. Radovi se mogu razvrstati na temelju metoda rješavanja u:

- egzaktne metode,
- heurističke metode,
- ekspertne sustave,
- pravila otpreme,
- umjetne neuronske mreže,
- metaheuristiku,
- hibridne pristupe,
- simulacije.

3.1.1. Egzaktne metode

Pristupi rješavanja egzaktnim metodama temelje se na pronalasku optimalnih rasporeda korištenjem matematičkih jednadžbi i nejednadžbi uz određena ograničenja (Talbi, 2009.). Takav pristup koristi skup pravila koji se temelji na karakteristikama rasporeda i matematičkim svojstvima problema.

Postoje različite tehnike koje se mogu koristiti prema problemu koji treba riješiti. Jedne od tehnika karakterističnih za takav pristup rješavanju problema su linearno programiranje i cjelobrojno programiranje. Linearno programiranje (engl. *Linear Programming*, LP) se koristi za ograničene probleme optimiranja u kojima se linearna funkcija cilja mora optimirati (maksimizirati ili minimizirati) uz uvjete ili ograničenja koja su dana u obliku jednadžbi i/ili nejednadžbi. Pritom varijable odlučivanja moraju biti nenegativne. Jedan od autora koji je koristio LP je Alfares (2011.). Koristio je LP za izradu plana proizvodnje baterija u srednje velikom poduzeću. Razlika između linearnog i cjelobrojnog programiranja je u tome što kod cjelobrojnog programiranja (engl. *Integer Programming*, IP) su varijable odlučivanja cjelobrojne. Jedna od najpoznatijih metoda za rješavanje linearnog programiranja je metoda grananja i ograđivanja (engl. *Branch and Bound*, B&B). Metoda grananja i ograđivanja koristi tzv. „podijeli pa vladaj“ pristup te dijeli cijeli skup na manje podskupove (Michalewicz i Fogel, 2004.). Korištenjem granica izbjegava se procjenjivanje cijelog skupa, nego se procjenjuju određeni dijelovi skupa (Voutsinas i Pappis, 2010.). Ovakav pristup koriste i druge metode, poput dinamičkog programiranja (engl. *Dynamic Programming*, DP). Međutim, ovakvi pristupi

su često neprikladni ili su čak i neizvedivi zbog velikog prostora rješenja pri razmatranju većih problema (Goldberg, 1989.). Pogotovo pri rješavanju složenih problema iz realnog okruženja gdje nije moguće pronaći rješenja bez velikih pojednostavljenja. S druge pak strane, ta pojednostavljenja neće pružiti valjana rješenja.

3.1.2. Heurističke metode

Heuristika predstavlja postupak koji vodi prema otkriću li ga potiče (www.enciklopedija.hr). Prema tome heurističke metode su metode koje vode prema pronalasku zadovoljavajućeg rješenja. Bitno svojstvo heurističkih metoda je da mogu približno (dovoljno dobro) riješiti najteže kombinatorne probleme optimiranja (Chen, 1995.). Ipak, heurističke metode ne moraju pronaći zadovoljavajuće rješenje.

Jedan od najjednostavnijih heurističkih algoritama korištenih za problem planiranja redoslijeda je pohlepni algoritam (engl. *Greedy Algorithm*). Pohlepni algoritam pronalazi optimalno rješenje problema koristeći slijed izbora, odnosno za svaku točku odluke u algoritmu odabire izbor koji je u tome trenutku najbolji (Ribas i sur., 2011.). Može se primjenjivati za rješavanje najsloženijih problema, jer prilikom svakog izbora smanjuje prostor pretraživanja, a samim tim smanjuje i složenost problema. U svakom trenutku pohlepni algoritam usmjerava prema trenutno najboljem rješenju, ali ne uzima u obzir da to ne mora biti optimum. Iz tog razloga, pohlepni algoritam ne mora uvijek pronaći optimalno rješenje.

3.1.3. Ekspertni sustavi

Ekspertni sustavi zapravo predstavljaju pristupe koji se temelje na znanju, tj. ljudskom iskustvu uz pomoć kojeg mogu riješiti problem iz područja za koji su napisani. Oslanjaju se na pravila koja vrednuju i određuju rasporede na sličan način kako to određuje stručnjaci u realnom okruženju. Takvi sustavi moraju sadržavati:

- ulazno-izlazne komponente koje sadrže informacije vezane za narudžbe (radne naloge)
- primjenjiva pravila pohranjena u bazi znanja
- logičku komponentu koja obrađuje podatke pomoću pravila u bazi znanja

Kod velikog broja postavljenih pravila pojavljuje se mogućnost pronalaska više rješenja. Osim toga, takav ekspertni sustav s velikim brojem postavljenih pravila teško je upotrebljiv u realnom

vremenu, što predstavlja glavni nedostatak ovakvog pristupa. Pregled radova koji su se bavili problemom planiranja proizvodnje koristeći ekspertne sustave za pronalazak rješenja, dali su Metaxiotis i sur. (2002.).

3.1.4. Pravila otpreme

U situacijama kada je potrebno više vremena za stvarno rješavanje problema s optimalnim rasporedom nego što je potrebno za stvarno izvršenje radnog naloga u proizvodnom pogonu s bilo kojim zadanim redoslijedom, tada se u praksi često koriste pravila otpreme (Ochoa i sur., 2009.). Pravila otpreme ili dispečerska pravila (engl. *dispatching rules*), za razliku od drugih metoda i tehnika, ne utječu direktno na određivanje redoslijeda nego određuju koji će radni zadatak imati prednost pred drugim radnim zadacima u određenoj fazi proizvodnje, odnosno na određenom radnom mjestu (Sharma i Jain, 2014.). Tablicom 3.1. dana su pravila otpreme koja se najčešće pojavljuju u literaturi. Također, danas se sve više primjenjuju različite kombinacije pravila otpreme kako bi se procijenili različiti ciljevi (Vinod i Sridharan, 2008.).

Tablica 3.1. Lista pravila otpreme

Pravilo otpreme	Opis
Prvi stigao, prvi poslužen (engl. <i>First Come First Served</i> , FCFS)	Odabir prvog radnog zadatka iz niza radnih zadataka koji čekaju na izradu na istom radnom mjestu
Najraniji rok isporuke (engl. <i>Earliest Due Date</i> , EDD)	Odabir radnog zadatka s najranijim rokom isporuke
Najkraće vrijeme izvođenja operacije (engl. <i>Shortest Processing Time</i> , SPT)	Odabir radnog zadatka s najkraćim vremenom operacije na istom radnom mjestu
Najdulje vrijeme izvođenja operacije (engl. <i>Longest Processing Time</i> , LPT)	Odabir radnog zadatka s najduljim vremenom operacije na istom radnom mjestu
Najkraće pripremno-završno vrijeme (engl. <i>SIMilar SETup time</i> , SIMSET)	Odabir radnog zadatka s najkraćim vremenom pripreme i raspreme radnog mjesta
Najviše operacija preostaje (engl. <i>Most Operations Remaining</i> , MOR)	Odabir radnog zadatka s najvećim brojem preostalih operacija za izvođenje
Najmanje operacija preostaje (engl. <i>Least Operations Remaining</i> , LOR)	Odabir radnog zadatka s najmanjim brojem preostalih operacija za izvođenje
Slučajan odabir (RANDOM)	Odabir radnog zadatka nasumičnim odabirom

3.1.5. Umjetne neuronske mreže

Umjetne neuronske mreže predstavljaju pristup koji se bazira na funkcioniranju biološkog mozga. Nastoje simulirati postupak učenja i obrade podataka. Osnovna ideja neuronskih mreža za rješavanje problema planiranja redoslijeda je prepoznavanje uzoraka u „dobrim“ rasporedima. Prilagođava se podacima dobivenih učenjem i njihovim prihvatljivim rješenjima. Pregledni rad vezan za planiranje redoslijeda radnih zadataka u proizvodnji upotrebom umjetnih neuronskih mreža dali su Akyol i Bayhan (2007.).

3.1.6. Metaheuristika

Metaheuristički pristupi uglavnom se sastoje od sljedećih koraka:

1. stvoriti početno rješenje i procijeniti ga prema postavljenom cilju,
2. generirati nova rješenja i procijeniti ih,
3. odabrati najbolje rješenje.

Jedan od metaheurističkih pristupa je i lokalno pretraživanje (engl. *Local Search*, LS). Tehnika lokalnog pretraživanja nastoji pronaći optimalno rješenje zadanog problema smanjujući prostor pretraživanja (Bagheri i Zandieh, 2011.). Može se opisati u nekoliko koraka. Najprije se odabere jedno rješenje te se procijeni njegova vrijednost. Zatim se pretražuju susjedi od odabranog rješenja i u ovisnosti o njihovim vrijednostima izabere se najbolji. Susjedi su pri tome definirani ovisno o problemu koji se promatra. Nakon toga se nizom iteracija nastoji doći do optimalnog rješenja. Pretraživanje je ograničeno brojem iteracija, te završava nakon definiranog broja iteracija. Neovisno o tome je li najbolje rješenje pronađeno.

U literaturi se za problem planiranja redoslijeda također koristi i metoda uspona (engl. *Hill-Climbing Search*). Zasniva se na kretanju kroz stablo u smjeru porasta, odnosno pada heurističke funkcije. Metoda uspona ne pamti stablo pretraživanja, već pamti samo aktivno stanje. Iz aktivnog stanja metoda uspona odabire trenutno najbolje rješenje prema vrijednosti funkcije cilja i proglašava ga aktivnim stanjem. Međutim, metoda uspona ima određene nedostatke zbog kojih se ne može napraviti sljedeći korak ili odabir sljedećeg koraka neće biti jedinstven. Ti nedostaci se pojavljuju ukoliko su rješenja na aktivnom čvoru lošija od rješenja na prethodnom čvoru ili slijedni čvorovi imaju iste vrijednosti. Iz tog razloga ova metoda je gotovo neupotrebljiva za složene probleme planiranja redoslijeda.

Tabu pretraživanje (engl. *Tabu Search*, TS) je metoda pretraživanja koja kombinira lokalno pretraživanje s kratkotrajnom memorijom. Metoda koristi posebnu listu, tabu popis, koja služi kao kratkotrajna memorija. Tabu popisom pamti određeni broj rješenja iz prethodnih koraka. Na taj način osigurava da se iste sekvence ne procjenjuju ponovno. Ponašanje metode ovisi o veličini tabu popisa. Ukoliko je veličina tabu popisa premala, može dovesti do cikličkog ponavljanja rješenja. S druge strane, ako je prevelika može dovesti do znatnog usporenja pretraživanja. Kada se odredi novo rješenje, iz tabu popisa se po FIFO (engl. *First In First Out*) principu izbacuje jedno rješenje i stavlja novo. Pronalazak redoslijeda (sekvenci) korištenjem tabu pretraživanja su između ostalih istraživali i Zhang i sur. (2007.) te Gao i sur. (2013.).

Metoda simuliranog kaljenja (engl. *Simulated Annealing*, SA) jedna je od stohastičkih optimizacijskih metoda, a razlikuje se od metode lokalnog pretraživanja po tome što omogućuje bijeg iz lokalnog optimuma. Prema autorima (Dreo i sur., 2006.) nastala je po analogiji s metalurškim kaljenjem, čiji je cilj oplemenjivanje metala tako da oni postanu čvršći. Metoda počinje odabirom nekog početnog rješenja, a početna temperatura ima relativno veliku vrijednost. Postojeće rješenje se zamjenjuje boljim, ali se može zamijeniti i s lošijim uz određenu vjerojatnost prihvatanja. Vjerojatnost odabira lošijeg rješenja je veća ukoliko je temperatura veća. To znači da je u početku prostor pretrage rješenja dosta velik i da se smanjuje padom temperature, a pri kraju procesa je usko lokaliziran te na taj način omogućava pronalazak optimalnih rješenja.

Optimizacija mravljeg roja (engl. *Ant Colony Optimization*, ACO) još je jedna u nizu metaheurističkih metoda koje se koristi za pronalazak rasporeda. Metoda se temelji na oponašanju mrava i njihovom odabiru puta od izvora hrane do mravljeg gnijezda. Provedenim pokusima u kojima je mravlje gnijezdo spojeno s izvorom hrane pomoću dva mosta čija se relativna duljina mijenjala, pokazalo se da će nakon nekog vremena većina mrava prolaziti kraćim putem. Razlog leži u posrednom načinu komunikacije mrava pomoću feromona kojeg ostavljaju za sobom (Dorigo i sur., 1996.). Grananjem puta na dvije dionice, vjerojatnost odabira bilo koje dionice puta jednaka je. Vrijeme potrebno za prolazak kraće dionice puta manje je u odnosu na dužu dionicu puta, što pretpostavlja da će kraćom dionicom puta proći više mrava za isto vrijeme. Što više mrava odabere isti put, na tom putu će biti i veća količina feromona. Svaki mrav donosi odluku na osnovu količine feromona kojeg osjeća na određenom putu. Kako se feromoni više osjećaju na kraćoj dionici puta, zbog njihove veće gustoće, većina

mrava će nakon nekog vremena prolaziti kraćim putem (Blum, 2005.). Ovu metodu su koristili Xing i sur. (2010.) za rješavanje problema redoslijeda radnih zadataka.

Posebnu skupinu metaheurističkih metoda za rješavanje mnogobrojnih problema predstavljaju evolucijski algoritmi (engl. *Evolutionary Algorithms*, EA). Talbi (2009.) navodi da evolucijski algoritmi svoju inspiraciju vuku iz Darwinove evolucijske teorije koja tumači da u prirodi vlada neprestana borba za opstanak. Drugim riječima, u prirodi neprestano teče proces prilagođavanja određene vrste okolini u kojoj živi, s ciljem preživljavanja. U određenoj populaciji neke vrste nastoje se očuvati dobra svojstva, a loša svojstva zamijeniti boljima. Uvjeti u prirodi određuju koje jedinke iz populacije će opstati. Razmnožavanjem jedinki osigurava se egzistencija određene vrste. Jedinke koje nastaju razmnožavanjem u pravilu nasljeđuju svojstva roditelja, ali zbog mutacija neka od tih svojstava mogu biti promijenjena. Te promjene svojstava predstavljaju ključ prilagodbe određene vrste novim uvjetima u prirodi. Glavna prednost evolucijskih pristupa u usporedbi s onim metodama koje se temelje na pretraživanju susjedstva (npr. simulirano kaljenje) je u tome što je potrebno manje procjena kako bi se pretražilo veće područje prostora rješenja (Dreo i sur., 2006.).

3.1.7. Hibridni pristupi

S ciljem pronalaska boljih i pouzdanijih rješenja za mnoge složene probleme iz stvarnog svijeta, pa tako i za probleme planiranja redoslijeda i planiranja veličine jediničnih serija, autori kombiniraju razne metode i tehnike optimizacije. Takve kombinacije različitih pristupa rješavanju problema nazivaju se hibridni pristupi. Primjer takvog pristupa je pohlepni nasumični postupak prilagodljivog pretraživanja, tzv. GRASP metoda. GRASP (engl. *Greedy Randomized Adaptive Search Procedure*) je kombinacija heuristike i lokalnog pretraživanja. Rješenje se sastavlja korak po korak uzimajući u svakoj iteraciji, slučajnim odabirom, komponentu rješenja iz ograničene liste kandidata. Ograničena lista kandidata se sastoji od najboljih elemenata rangiranih prema vrijednosti pohlepne funkcije, tj. prema kvaliteti rješenja koje bi mogli postići.

GRASP metodu koristili su Rajkumar i sur. (2010.) za optimiranje završetka proizvodnje i povećanje iskoristivosti proizvodnih kapaciteta. Još jedan primjer hibridnog pristupa primijenio je Perinić (2004.) koristeći tabu pretraživanje i genetski algoritam kako bi optimirao ciklus izrade na fleksibilnom proizvodnom sustavu (engl. *Flexible Manufacturing System*, FMS).

3.2. Genetski algoritmi

Genetski algoritmi (engl. *Genetic Algorithms*, GA) su metaheuristička metoda koja pripada skupini evolucijskih algoritama. Izvorno ju je opisao Holland (1975.), a kao i svaka druga metoda iz skupine evolucijskih algoritama imitira evolucijski proces. Evolucija je robustan proces pretraživanja prostora rješenja. Živa bića se tijekom evolucije prilagođavaju uvjetima u prirodi, tj. životnoj okolini. Analogija evolucije kao prirodnog procesa i genetskog algoritma kao metode optimiranja, očitava se u procesu selekcije i genetskim operatorima (Goldberg, 1989., Talbi, 2009.). Mehanizam odabira nad nekom vrstom živih bića u evolucijskom procesu čine okolina i uvjeti u prirodi. U genetskim algoritmima ključ selekcije je funkcija dobrote ili prilagođenosti koja na odgovarajući način predstavlja problem rješavanja. Prilagođenost je pokazatelj koliko je pojedina jedinka uspješna u ostvarenju tog cilja. Drugim riječima, predstavlja vjerojatnost pojedine jedinice da preživi dovoljno dugo kako bi se razmnožavala.

U kontekstu rješavanja problema rasporeda korištenjem genetskog algoritma pojedine jedinice unutar populacije zapravo predstavljaju kandidate za rješenje. Kvaliteta potencijalnih rješenja ovisna je o prilagođenosti koja uvjetuje kolika će biti vjerojatnost pojedinog kandidata za rješenje u stvaranju sljedećih kandidata. Poveznica navedenih pojmova nalazi se u tablici 3.2.

Tablica 3.2. Poveznica između pojmova iz teorije evolucije i genetskih algoritama

Evolucija	↔	Algoritam
Okolina	↔	Problem
Jedinka	↔	Kandidat za rješenje
Prilagođenost (dobrota)	↔	Kvaliteta rješenja

Proces prirodne selekcije ima glavni utjecaj na evoluciju. Okolinu čini određen broj jedinki koji može živjeti u njoj. Kako ne bi došlo do eksponencijalnog rasta populacije, potreban je određeni oblik prirodne selekcije. Prirodna selekcija favorizira one jedinice koje su najbolje prilagođene uvjetima okoline, odnosno onima koje mogu najbolje iskoristiti dostupne resurse (Goldberg, 1989.). Ovako opisana prirodna selekcija jedna je od dvije osnovne ideje teorije evolucije. Druga ideja je rezultat fenotipskih varijacija unutar populacije. Fenotip jedinice predstavlja pojedine karakteristike jedinice koje imaju izravan utjecaj na interakciju jedinice s okolinom. Drugim riječima, utječe na njenu prilagođenost, a samim tim i na vjerojatnost preživljavanja. Svaka jedinka je jedinstvena kombinacija fenotipskih karakteristika (Dreo i sur., 2006., Talbi,

2009.). Ukoliko okolina te karakteristike procijeni povoljno, onda se te karakteristike zadržavaju u populaciji i u sljedećim generacijama. U suprotnom, one se gube. Tijekom reprodukcije iz generacije u generaciju na fenotipu se događaju nasumične, slučajne varijacije u obliku mutacija. Rezultat tih varijacija je pojava novih kombinacija karakteristika, što omogućava evoluciju.

Ukratko, pojedina populacija sastoji se od određenog broja nasumičnih jedinki. Kolika je vjerojatnost da će se pojedina jedinka razmnožavati izravno je ovisna o prilagođenosti pojedine jedinke okolini. Razmnožavanjem uspješnijih jedinki, uz povremene varijacije, dolazi do pojave novih jedinki. Na taj način, uz dovoljno vremena, mijenja se cijela populacija odnosno ona evoluirala.

Genetski algoritmi su jedna od najčešćih metoda korištenih za rješavanje problema planiranja redoslijeda i veličine jediničnih serija. Razlog je u tome što ne zahtijevaju derivabilnost niti ovise o početnoj procjeni ekstrema, te uspješno pronalaze globalne ekstreme, a ne samo lokalne (Goldberg, 1989.). Navedeno ih čini vrlo učinkovitim alatom za rješavanje raznih problema, pa i onih najsloženijih (Perinić i Ljubetić, 2004.). Međutim, genetski algoritmi imaju određene nedostatke:

- nije uvijek sigurna konvergencija algoritma,
- nema univerzalnog pravila za točan izbor parametara algoritma kao što su veličina populacije, broj generacija, vjerojatnost križanja i vjerojatnost mutacije,
- genetski algoritam može trošiti značajno vrijeme prilikom pretraživanja te brzina konvergencije može biti vrlo spora,
- ponovljivost rezultata, uz ponovnu primjenu istih vrijednosti parametara, nije zajamčena.

3.2.1. Predstavljanje

U primjeni genetskih algoritama prvi korak je predstavljanje ili reprezentacija jedinki kao potencijalnih kandidata za rješenje. Način na koji predstaviti rješenje problema osnovni je problem primjene genetskih algoritama, jer se tim postupkom povezuju stvarni svijet i genetski algoritmi. Postavljanje zadatka optimizacije označava odabir određenog skupa parametara te funkcije cilja kojoj su ti parametri promjenjive veličine. Kada ti parametri poprime određene vrijednosti kao rezultat se dobiva točno određeno rješenje. Vrijednosti skupa parametara čine

fenotip određene jedinke. Kako genetski algoritmi funkcioniraju na razini gena, potrebno je poznavati genotip svake jedinke. Prema tome, potrebno je izvršiti preslikavanje fenotipa u genotip odnosno kodirati skup parametara u oblik umjetnog kromosoma. Navedeni postupak naziva se predstavljanje ili reprezentacija jedinki. Svi parametri odnosno karakteristike koje opisuju svojstva jedne jedinke mogu se zapisati u obliku jednog umjetnog kromosoma. Svaki umjetni kromosom zapravo je sastavljen od niza gena. Pritom pojedini gen predstavlja određenu karakteristiku promatrane jedinke.

Na početku, genetski algoritam stvara početnu populaciju koja je sastavljena od određenog broja jedinki. Svakoj jedinki dodjeljuju se određene vrijednosti za pojedinu karakteristiku, tj. dodjeljuju se vrijednosti svakom genu za svaki kromosom unutar populacije. Obično se vrijednosti nasumično generiraju. Generirani početni kromosomi predstavljaju prva, početna rješenja. Ovaj postupak često se naziva fazom inicijalizacije. Važno je naglasiti kako veličina populacije izravno utječe na vrijeme potrebno za odvijanje algoritma, ali isto tako i na kvalitetu krajnjeg rješenja. Većim brojem jedinki u populaciji povećava se vjerojatnost pronalaska optimuma, odnosno povećava vjerojatnost pronalaska optimuma za manji broj iteracija.

3.2.2. Selekcija

Nakon faze inicijalizacije, procjenjuje se svako od početnih rješenja izračunavanjem vrijednosti funkcije cilja za svako rješenje. Zatim, pomoću određenih pravila odabire se koja rješenja iz početne populacije će biti korištena za razmnožavanje, tj. reprodukciju. Postoji nekoliko varijanti odabira početnih rješenja kao roditelja koji će razmnožavanjem generirati novu populaciju, sljedeću generaciju. Objasniti će se dvije mogućnosti odabira koji se često koriste u literaturi, a to su:


- stohastički odabir - roditelji se odabiru slučajno prema njihovim vrijednostima funkcije cilja. Kod ovakve vrste odabira, jedinke s boljim vrijednostima funkcije cilja imat će veću vjerojatnost biti odabrane za razliku od onih jedinki s lošijim vrijednostima funkcije cilja. Drugim riječima, jedinka s najvećom vrijednošću funkcije cilja će imati najveću vjerojatnost biti odabrana za reprodukciju, dok će jedinka s najmanjom vrijednošću funkcije cilja imati najmanju vjerojatnost biti odabrana.
- nasumični odabir - ne koristi se funkcija cilja, nego se roditelji odabiru nasumično. Pritom svaka jedinka ima jednaku vjerojatnost biti odabrana za reprodukciju.

3.2.3. Genetski operatori

Odabrane jedinke predstavljaju roditelje, kao oca i majku, koji se razmnožavaju. Razmnožavanjem nastaju potomci, koji su zapravo klonovi svojih roditelja. Zatim se na potomke primjenjuju genetski operatori. Hoće li se genetski operatori primijeniti, ovisi o vjerojatnosti pojave genetskih operatora. Genetski operatori igraju važnu ulogu u stvaranju novih jedinki. Način rada genetskih operatora ovisi o osnovnom problemu rješavanja. Tri su vrste genetskih operatora: operator križanja, operator inverzije i operator mutacije.


Operator križanja primjenjuje se na potomke, na način da jedan potomak nasljeđuje dio gena od jednog a ostali dio gena od drugog roditelja, dok drugi potomak nasljeđuje preostale gene. Bitno je naglasiti da se proces križanja događa uz određenu vjerojatnost pojave, tako da se može dogoditi da uopće ne dođe do procesa križanja. U tom slučaju odabrane jedinke iz prethodne populacije ulaze u novu populaciju nepromijenjene. S obzirom na način nasljeđivanja gena razlikuje se nekoliko tipova križanja:

- a) Križanje u jednoj točki - odabire se nasumičan broj iz raspona $[0, \lambda - 1]$, gdje λ predstavlja duljinu niza gena. Nasumično odabran broj predstavlja točku prekida u kojoj se oba kromosoma presijecaju te se zamijene njihovi zadnji dijelovi, slika 3.1.




Slika 3.1. Križanje u jednoj točki - zadnji dijelovi niza gena se zamijene u točki prekida

- b) Križanje u više točaka - niz gena se presijeca na više od jedne točke. Potomci se dobivaju alterniranjem dijelova oba roditelja. Slikom 3.2. je dan primjer križanja u tri točke.



Slika 3.2. Križanje u tri točke - dijelovi niza gena iza točaka prekida se zamijene

- c) Uniformno križanje - svaki gen se promatra zasebno te se nasumično bira roditelj od kojeg će ga naslijediti. Ova metoda se najčešće implementira pomoću λ slučajnih varijabli iz uniformne razdiobe $[0,1]$, gdje je λ jednak nizu gena. Na svakoj poziciji, ukoliko je vrijednost slučajne varijable ispod određene vrijednosti (najčešće 0.5) taj gen se kopira od prvog roditelja, u suprotnom od drugog roditelja. Drugi potomak se dobije suprotnim postupkom. Vidi sliku 3.3.



Slika 3.3. Uniformno križanje - svaki gen se nasumično bira između roditelja

Operator inverzije invertira redoslijed unutar definiranog raspona jedinke. Najprije odabire raspon slučajne inverzije, a zatim preokreće slijed gena unutar tog raspona, prikazano slikom 3.4. Pritom, nasumično odabire dvije pozicije u nizu gena te zamijeni njihov poredak.



Slika 3.4. Inverzija dijela niza gena između pozicija 2 i 5

Operator mutacije slučajno mijenja pojedinačne gene. Predstavlja najvažniji parametar genetskog algoritma iz razloga što radi slučajne skokove algoritma po prostoru rješenja. Na taj način omogućava algoritmu izbjeći zaglavljivanje u lokalnom optimumu i proširiti područje pretrage na još neistražene dijelove prostora rješenja, te se tako približiti globalnom optimumu.

Genetski algoritam je jako osjetljiv i na najmanje promjene ovoga parametra, te je potrebno jako pažljivo odabrati njegove vrijednosti (Goldberg, 1989.). Ovisno o vrsti problema rješavanja razlikuje se nekoliko različitih tipova operatora mutacije:

- a) Mutacija zamjenom - zamjenjuje pozicije dva slučajno odabrana gena, vidi sliku 3.5.



Slika 3.5. Mutacija zamjenom - zamjenjuju se pozicije 3 i 5

- b) Mutacija umetanjem - nasumično odabere dva gena na način da jednog pomakne tako da bude pokraj drugog odabranog gena, a ostale prema potrebi pomakne za jedno mjesto udesno, slika 3.6.




Slika 3.6. Mutacija umetanjem gena s pozicije 5 na poziciju 3, a ostali geni se pomiču za jedno mjesto udesno

- c) Mutacija permutiranjem - cijeli niz gena ili neki njegov podskup nasumično permutira. Na slici 3.7. je dan primjer s permutiranim podskupom od treće do šeste pozicije.



Slika 3.7. Mutacija permutiranjem dijela niza gena između pozicija 3 i 6

- d) Mutacija dodjelom - operator mutacije nasumično određuje vrijednost iz skupa dodjele ili odabire vrijednost iz definiranog intervala, a zatim tu vrijednost dodjeljuje nasumično odabranom genu (slika 3.8.).



Slika 3.8. Mutacija dodjelom - genu na poziciji 4 dodijeljena je nova vrijednost

Generiranjem nove populacije, procjenjuje se svaka nova jedinka određivanjem vrijednosti funkcije cilja za svaku jedinku. Kako bi se odabrale jedinke za sljedeću generaciju potrebno je odrediti način odabira jedinki. Nekoliko je načina na koje genetski algoritam odabire jedinke koje će koristiti u sljedećoj generaciji. Između ostalih, to su:

- 1 od 2 odabir - koristi samo djecu kao dva rješenja i odabire rješenje s boljom vrijednošću funkcije cilja.
- 1 od 4 odabir - koristi roditelje i djecu kao rješenja i odabire najbolje rješenje.
- probabilistički odabir - koristi roditelje i djecu kao rješenja te odabire rješenje stohastičkim odabirom. Vjerojatnosti odabira proporcionalne su kvaliteti rješenja.
- nasumični odabir - odabire slučajno pojedinca za novu generaciju bez obzira na vrijednost funkcije cilja.

3.2.4. Uvjet zaustavljanja

Postizanje određenog rješenja je jedan od uvjeta zaustavlja algoritma, no često je nemoguće predvidjeti rješenje. Zbog toga se kao uvjet zaustavljanja postavlja broj iteracija odnosno broj stvorenih generacija određene populacije. Broj iteracija je parametar koji ima izravan utjecaj na vrijeme izvođenja algoritma kao i na kvalitetu dobivenih rješenja (Gupta i sur., 1996.). Veći broj iteracija rezultirat će boljim rješenjem. Međutim, veći broj iteracija iziskuje i više vremena koje će genetski algoritam potrošiti na svoje izvođenje (Gen i Cheng, 1997.). Stoga je važno odrediti dovoljan broj iteracija za pronalazak prihvatljivog rješenja.

Važno je napomenuti da optimalno rješenje često nije cilj kojem se teži. Cilj kojem se teži je pronaći što bolje rješenje u što kraćem vremenu. Rješenje koje je dovoljno blizu optimuma a za koje je potrebno puno manje vremena kako bi se došlo do njega je zadovoljavajuće rješenje. Pronalazak takvog rješenja koje karakterizira relativno visoka performansa izvedbe moguće je postići korištenjem genetskih algoritama.

Slijedom svega navedenog, kako bi se definirao genetski algoritam potrebne su sljedeće komponente:

- funkcija cilja (prilagođenost),
- populacija,
- način inicijalizacije populacije,

- mehanizam odabira roditelja,
- operatori križanja i mutacije,
- mehanizam odabira jedinki za sljedeću generaciju,
- uvjet zaustavljanja.

3.3. Metode simulacije

Bilo koji oblik razvoja u proizvodnim okruženjima za posljedicu ima mijenjanje postojećeg stanja, no te promjene su neophodne za opstanak i konkurentnost proizvodnih poduzeća na tržištu (Ištoković i sur., 2020.). Svaka promjena koja se radi direktno u proizvodnom sustavu, odnosno promjene unutar proizvodnog procesa često su vrlo skupe. Pogotovo ako rezultati nisu onakvi kakvi su se očekivali. Za izbjegavanje takvih oblika problema, a samim time i nepotrebnih troškova, danas se sve više pristupa simulaciji stvarnih (realnih) proizvodnih procesa. Greške koje se pojave unutar simulacije jednostavnije je ispraviti nego ako se pojave u realnom svijetu, u stvarnom proizvodnom sustavu.

Simulacija je vrlo moćna i široko korištena znanstvena tehnika upravljanja za analizu i proučavanje složenih sustava (Ištoković i sur., 2019.a). Omogućava proučavanje stvarnog procesa pomoću njegovog modela na računalu (Robinson, 2004.). Predstavlja proces rješavanja stvarnih problema izvođenjem eksperimenata (Čerić, 1993.). Simulacijom se ispituju brojni scenariji stvarnog procesa kako bi se potencijalne promjene mogle predvidjeti i prilagoditi.

Ova metoda može se upotrijebiti u mnogim i raznolikim znanstvenim granama, od društvenih i prirodnih, pa tako i u tehničkim (Johansson i sur. 2009.). Prema Mourtzisu (2019.), primjena simulacije vidljiva je u različitim procesima iz realnog okruženja, poput sustava proizvodnje, sustava uslužnih djelatnosti, prognoziranja prodaje na tržištu, planiranja zaliha, alokacija resursa, itd. Svoj nastanak i razvoj, simulacija može zahvaliti pojavi računala. U praksi se simulacije koriste za verifikaciju analitičkih modela, odnosno za ispitivanje ponašanja nekog sustava, tj. njegove reakcije na različite parametre. Najčešće se koristi za analizu „što ako“ pitanja (engl. *what if*), ali i za standardizaciju procesa i procedura te analizu osjetljivosti procesa na promjene (Dušak, 1992.).

Dakle, za simulaciju je karakterističan široko primjenjiv pristup u kojem se neka pojavnost promatra kao sustav, koji se dalje može proučavati uz pomoć računala. Iz ovoga slijedi da je

simulacija naročito korisna kada je promatrani sustav vrlo složen, tj. kada se sastoji od velikog broja podsustava i veza gdje neke veličine imaju slučajni karakter ili nisu ni poznate.

Uz već spomenutu činjenicu da se može upotrebljavati u različitim granama znanosti, to je čini vrlo moćnim alatom za rješavanje širokog spektra problema. Simulacija je metoda koja omogućuje veliku raznolikost i prilagodljivost u modeliranju te jednostavne naknadne izmjene u modelu. Na modelu se mogu provoditi eksperimenti neograničen broj puta, s istim ili promijenjenim parametrima.

Simulacija daje podatke o mogućem ponašanju stvarnog sustava u ovisnosti o nekom početnom uvjetu (Čerić, 1993.). Pouzdanost dobivenih podataka ovisi o tome koliko je precizno izrađen model te o mogućnostima simulatora i simulacijskog jezika, tj. s dobro planiranom i izvedenom simulacijom može se postići vrlo visoka točnost opisivanja procesa u realnom sustavu. Važno je napomenuti da je simulacija samo apstrakcija realnog sustava te se modeliraju samo oni dijelovi sustava koji su bitni za istraživanje ponašanja realnog sustava. Cijeli realni sustav se sastoji od prevelikog broja varijabli koje utječu na sustav što dovodi do njegovog pojednostavljenja pa rezultati mogu biti previše optimistični i idealni. Temeljem te spoznaje, rezultate simulacija potrebno je interpretirati s određenom dozom opreza.

Svaka tehnika, svaka metoda, pa tako i simulacija ima svoje prednosti i nedostatke. Glavna prednost simulacijskog modeliranja je mogućnost detaljnog predstavljanja složenih sustava iz stvarnog svijeta (Frantzen, 2015.), a to podrazumijeva uključivanje više varijabli koje nije moguće riješiti matematičkim postupcima, bez ometanja rada realnog sustava (Božikov, 2007.). Isto tako, velika prednost simulacije je u tome što je teorija simulacije relativno jednostavna. Općenito, metode simulacije lakše se primjenjuju nego analitičke. Dok analitički modeli mogu zahtijevati mnoge pojednostavljjuće pretpostavke, simulacijski modeli imaju malo takvih ograničenja, što omogućava mnogo veću fleksibilnost u predstavljanju realnog sustava. Jednom kada se model izradi, može se više puta koristiti za različite analize. Naprimjer, ako proizvodno poduzeće ima simulacijski model svog skladišta, na modelu se mogu isprobati razne politike zaliha. Pritom nema potrebe za eksperimentalnim istraživanjima na realnom sustavu (Winston i Goldberg, 2004.).

Međutim, veliki nedostatak simulacija je potreba za poznavanjem velikog broja odgovarajućih alata i metoda modeliranja što dovodi do toga da je proces dugotrajan. Uz to, simulacija nije tehnika optimizacije. Optimizacija uz simulaciju je moguća, ali to dodatno usporava proces.

Također, simulacija može biti vrlo skupa. Razvojem simulacijskih jezika za posebne namjene i napretkom simulacijskih metodologija problem troškova postaje manje bitan (Winston i Goldberg, 2004.).

3.3.1. Sustav

Sustav predstavlja dio stvarnog svijeta koji se promatra. Može se definirati kao skup određenih dijelova koji međusobnim djelovanjem vode prema ostvarenju nekog logičkog cilja (Schmidt i Taylor, 1970., Winston i Golberg, 2004.). Dijelovi su međusobno povezani vezama. Pomoću njih mogu djelovati jedan na drugoga tako da svi zajedno djeluju kao cjelina. Osnovno obilježje sustava je interakcija njegovih dijelova, gdje interakcije između dijelova mogu biti različite (Mikac i Ikonić, 2008.). Njihovim mijenjanjem mijenjaju se kvalitativna svojstva dijelova i cjeline. U literaturi se dijelovi često još nazivaju entiteti (Čerić, 1993.) ili objekti (Winston i Goldberg, 2004.).

Međutim, u praksi je definicija sustava obično fleksibilnija. Točan opis sustava obično ovisi o ciljevima simulacijske studije. Razlog leži u tome da ono što može biti sustav za jednu studiju, za drugu može biti samo podskup cjelokupnog sustava (Winston i Goldberg, 2004.), odnosno svaki dio može predstavljati sustav za sebe (Robinson, 2004.). Ukratko, sustav je hijerarhijska struktura sastavljena od njegovih dijelova i veza između njih. Dijelovi sustava koji se modelira, kao komponente sustava, mogu biti stalni (ostaju u modelu tijekom cijelog trajanja simulacije, npr. strojevi) i privremeni (prolaze kroz sustav i ne ostaju u modelu tijekom cijelog trajanja simulacije, npr. izradak). Svaki dio može sadržavati nekoliko atributa kojima se opisuju svojstva entiteta (npr. vrijeme operacije).

3.3.2. Stanje sustava

U svakom vremenskom trenutku sustav se nalazi u nekom stanju. Ukupno stanje sustava određeno je stanjima svih njegovih dijelova. Kao što sustavu odgovara model, tako i stanju sustava odgovara stanje modela. Stvarnim promjenama stanja sustava odgovaraju promjene stanja modela tijekom simulacije. Kako bi se opisao sustav koristi se pojam stanja sustava. Stanje sustava zapravo predstavlja skup varijabli koje su neophodne za opisivanje sustava u bilo kojem vremenskom trenutku (Winston i Goldberg, 2004.). Definira se entitetima koje model sadrži i vrijednostima atributa (Seila i sur., 2003.).

3.3.3. Realni sustav

Realnim sustavom se smatra izdvojeni dio stvarnog svijeta koji čini funkcionalnu cjelinu (npr. trenutni proizvodni pogon). Također, realnim sustavom se može smatrati i nešto što u stvarnosti ne postoji nego je zamišljeno, odnosno planirano napraviti u budućnosti (npr. novi, budući proizvodni pogon).

3.3.4. Model

Model predstavlja sredstvo kojim se opisuje određeni realni sustav. Modelom se daje pojednostavljeni prikaz realnog sustava, tj. ne prikazuje se cijeli realni sustav nego samo najbitniji aspekti. Iz tog slijedi da model opisuje sustav samo s određenom razinom točnosti. Stanje sustava se u modelu predstavlja vrijednostima varijabli stanja. Vrijednosti varijabli stanja predstavljaju veličine iz stvarnog sustava, a promjene predstavljaju promjenu stanja sustava.

Modeli se mogu podijeliti (Božikov, 2007.):


- prema strukturi
 - fizičke - model predstavlja u većoj ili manjoj mjeri fizičku kopiju određenog objekta,
 - apstraktne - pojedini elementi modela prikazani su simbolima ili brojčanim vrijednostima (apstraktnim pojmovima),
- prema ponašanju
 - statičke - ne ovise o vremenu nego su prikaz sustava u jednom trenutku,
 - dinamičke - ovise o vremenu te predstavljaju sustave koji se vremenski razvijaju,
- prema načinu rješavanja
 - konceptualne,
 - matematičke,
 - simulacijske.

Tri vrste modela prema načinu rješavanja predstavljaju svojevrсна tri stupnja razvoja modela. Najprije se prikazuje koncept modela kroz opise riječima te shematski prikaz. Na taj način se omogućava strukturiranje problema i njegovo bolje razumijevanje. Nakon toga se formira u obliku matematičkog modela korištenjem skupova jednadžbi i logičkih operatora kojima se

uspostavlja odnos između varijabli. Na kraju se implementira u programski alat kojim će se simulirati promjena realnog sustava tijekom određenog vremenskog perioda.

3.3.5. Koncept simulacije

Osnovni koncept simulacijskog procesa može se opisati na sljedeći način, slika 3.9. Najprije je potrebno promatrani stvarni sustav (postojeći ili nepostojeći) opisati modelom. Varijablama stanja određuje se stanje modela, a stanjem modela predstavlja se stanje sustava. Model predstavlja sustav sa željenom razinom aproksimacije. Zatim slijedi izrada modela odnosno modeliranje u kojem se model zadaje određenim simulacijskim jezikom karakterističnim za svaki programski alat. Izradom modela, pristupa se samom simuliranju koje se odvija uz pomoć simulatora, posebnog programa na računal, pri čemu je rad simulatora upravljan modelom. Završetkom simulacije dobiveni su različiti podaci koji se mogu upotrijebiti u razne svrhe. Interpretacijom dobivenih rezultata uočava se kakvo je njihovo značenje za promatrani sustav.



Slika 3.9. Osnovni koncept simulacijskog procesa (Božikov, 2007.)

Proces rješavanja stvarnih problema korištenjem simulacije može se opisati nizom koraka koji čine pojedine faze rješavanja problema. Ne moraju nužno slijediti jedan drugog jer je moguć povratak na prethodne korake procesa, ovisno o rezultatima dobivenim u pojedinim fazama tog procesa. Autori Law i Kelton (2000.) te Bangsow (2010.), definirali su simulacijski proces kroz sljedeće osnovne korake:

1. Definicija cilja simulacijske studije - potrebno je odrediti ciljeve simulacijske studije kako bi svrha postala jasna. Glavni cilj (npr. smanjenje troškova proizvodnje) se može podijeliti u manje ciljeve koji su međusobno u interakciji.
2. Identifikacija sustava - s obzirom na problem rješavanja potrebno je analizirati i procijeniti isplativost simulacije promatranog sustava. Postoji li nedostatak matematičkih modela, velika složenost (puno varijabli) i tome slično.
3. Prikupljanje i analiza podataka o sustavu - potrebno je osigurati sve nužne podatke o sustavu.
4. Izrada simulacijskog modela - izrađuje se simulacijski model na temelju prikupljenih podataka. Pritom se stvarni sustav prikazuje na način koji je omogućen simulacijskim jezikom.
5. Provjera simulacijskog modela ili verifikacija - ponaša li se simulacijski model onako kako je zamišljeno. Verifikacija se provodi prethodnim izračunavanjem očekivanog stanja modela a zatim simuliranjem. Model se smatra valjanim ukoliko se izračunati rezultati podudaraju s rezultatima dobivenim simuliranjem.
6. Vrednovanje simulacijskog modela ili validacija - ispitivanje koliko je dobro promatrani sustav opisan izrađenim simulacijskim modelom. Validacija se provodi tako da se kao ulaz simuliranog modela koriste ulazne varijable iz realnog sustava za koje su poznate izlazne varijable. Nakon simulacije uspoređuju se dobiveni rezultati s onima iz realnog sustava. Ako se poklapaju tada je modeliran sustav valjan.
7. Planiranje i izvođenje simulacijskih eksperimenata - pokretanje i izvršenje simulacije za definirane parametre te prikupljanje dobivenih podataka.
8. Analiza rezultata eksperimenata - provodi se analiza najvažnijih parametara. Ispravnom interpretacijom rezultata simulacije znatno se utječe na uspješnost simulacijske studije. Ukoliko su rezultati u suprotnosti s iznesenim pretpostavkama, potrebno je analizirati koji su utjecaju odgovorni za neočekivane rezultate.
9. Zaključci i preporuke - na kraju donesene zaključke potrebno je ažurirati te dati upute za buduća ispitivanja

3.3.6. Simulacijski model

Kako bi se donijele kvalitetne odluke u analizi postojećeg proizvodnog sustava ili u implementaciji novog provodi se simulacija. Realnu proizvodnju, između ostalog,

karakteriziraju mnogi nepredvidivi (stohastički) faktori poput kvarova proizvodne opreme, zakašnjele dobave materijala, i tome slično. Simulacijskim modelom takvi faktori se mogu obuhvatiti što omogućava vjerodostojan prikaz realnog stanja (Božikov, 2007.). Obično ima oblik skupa pretpostavki o radu sustava, izraženih kao matematički ili logički odnosi između entiteta koji su od interesa za sustav.

Za razliku od egzaktnih matematičkih rješenja dostupnih kod većine analitičkih modela, postupak simulacije uključuje izvršavanje ili pokretanje modela kroz vrijeme, obično na računalu, radi stvaranja reprezentativnih uzoraka mjera učinkovitosti (uspješnosti). U tom pogledu, simulacija se može promatrati kao eksperiment uzorkovanja na stvarnom sustavu, a rezultati se ogledaju kroz bodove. Na primjer, da bi se dobila najbolja procjena prosječne mjere učinkovitosti, usporede se rezultati uzoraka. Jasno, što se više uzoraka generira, to će procjena biti bolja. Međutim, i drugi čimbenici poput početnog uvjeta simulacije, duljine razdoblja koje se simulira i točnosti samog modela, mogu imati utjecaj na to koliko će konačna procjena biti dobra.

Simulacijski model se koristi u svrhu analize određenog sustava ili procesa bez narušavanja trenutnog stanja te zbog mogućnosti uvida u različite dijelove sustava kao i njihove interakcije. Varijabilnosti realnog sustava uzete su u obzir izrađenim simulacijskim modelom što omogućava bolje rezultate vezanih za utjecaj određenih promjena u određenom vremenskom periodu. Isto tako, simulacijskim modelom lako se vizualizira problem te prenose ideje o rješenju kroz animacije i grafičke prikaze određenog eksperimenta (Čerić, 1993.).

Ukratko, simulacijski model mora biti dovoljno fleksibilan da se nosi s promjenama u fizičkoj konfiguraciji, dovoljno brz kako bi se raspored mogao generirati u prihvatljivom vremenu te dovoljno detaljan uz odgovarajuću razinu pojednostavljenja.

Simulacijski modeli mogu se podijeliti prema:

- vrsti varijabli u modelu (determinističke i stohastičke)
- načinu na koji se stanje modela mijenja u vremenu (diskretno i kontinuirano)

Deterministički model je model u kojem su ishodi poznati, oni koji se mogu predvidjeti, a određeni ulazni podaci daju uvijek iste izlazne podatke. Stohastički model s druge strane predstavlja situaciju u kojoj postoji neizvjesnost. Drugim riječima, stohastički model karakterizira slučajno ponašanje. Simulacija u kojoj se varijable stanja mijenjaju u diskretnim

vremenskim točkama naziva se simulacijom diskretnih događaja. S druge strane, ukoliko se varijable stanja mijenjaju kontinuirano tijekom vremena, tada se govori o kontinuiranoj simulaciji.

Za izradu simulacijskog modela nema striktnih pravila. Ipak, iskustvo velikog broja istraživača koji su se time bavili dovelo je do općih preporuka za izradu simulacijskih modela (Gordon, 1978.):

- Granica sustava s okolinom mora biti odabrana tako da sustav, odnosno njegov model, obuhvaća samo fenomene od interesa. Okolina sustava modelira se tako da se ne uključuju detalji i uzročne veze među njima, nego se daje samo njihov sažeti prikaz (npr. slučajna razdioba dolazaka u sustav).
- Modeli ne smiju biti previše složeni ni detaljni, nego treba modelirati samo relevantne elemente sustava. Suviše složene i detaljne modele teško je ili čak nemoguće razumijeti i vrednovati, što znači da su i njihov razvoj i uporaba teški te neizvjesne kvalitete.
- Modelom se ne smije niti previše pojednostavniti problem npr. izbacivanjem varijabli nužnih za adekvatni opis sustava ili prevelikim stupnjem agregiranja dijelova sustava.
- Model je razumno rastaviti na više dobro definiranih i jednostavnih modula s točno određenom funkcijom koju je lakše izgraditi i provjeriti.
- U razvoju modela preporučuje se primjena neke provjerene metode za razvoj algoritma i programa koja treba omogućiti bolje razumijevanje modela i pojedinih njegovih modula u svim fazama razvoja modela.
- Potrebna je provjera logičke i kvantitativne ispravnosti modela, i to kako pojedinačnih modula, tako i cijelog modela. Kod modela koji uključuju slučajne varijable to znači i primjenu odgovarajućih statističkih tehnika.

3.4. Simulacija diskretnih događaja

Proizvodne sustave iz realnog svijeta moguće je simulirati kroz simulaciju diskretnih događaja. Upotreba DES-a kao pomoć pri donošenju odluka narasla je tijekom posljednjih godina (Banks i sur., 2010., Montevechi i sur., 2012.). DES predstavlja moćne i učinkovite alate za rješavanje mnogih problema iz realnog okruženja. Jedna su od najčešće korištenih tehnika za analizu i razumijevanje dinamike proizvodnih sustava zbog svoje svestranosti i fleksibilnosti. To se

može vidjeti iz velikog broja objavljenih radova (Jahangirian i sur., 2010., Ryan i Heavey, 2006., Ištoković i sur., 2020.).

DES se opisuje kao proces kodiranja ponašanja složenih sustava kao slijeda čvrsto definiranih događaja (Banks i sur., 2010.). Pri čemu događaj predstavlja specifičnu promjenu u stanju sustava u nekom posebnom vremenskom trenutku. Može nastupiti zbog ulaska ili izlaska entiteta u sustav (npr. ulaz jedinične serije proizvoda u sustav), zbog promjene vrijednosti atributa (npr. ako se promijeni brzina rezanja na stroju) i tome slično. Događaji mogu biti uvjetni odnosno oni koji se mogu dogoditi tek onda kada je ispunjen neki uvjet ili bezuvjetni (planirani) odnosno oni koji se odvijaju nakon prolaska određenog vremena (npr. završena obrada jedne jedinične serije proizvoda na jednom stroju). Promjene stanja unutar simulacija diskretnih događaja odvijaju se diskontinuirano u vremenu, pri čemu su promjene stanja posljedica međudjelovanja između entiteta sustava (npr. stroj napravi obradu na jedinici proizvoda, obrada jedinice proizvoda je završena i njeno stanje se mijenja). Diskontinuirana odnosno diskretna promjena vremena zapravo predstavlja da od trenutka kada se dogodio posljednji događaj vrijeme „skače“ na trenutak u kojem će se dogoditi sljedeći događaj. I tako za svaki događaj. Unutar svakog DES-a nalazi se simulacijski sat koji mjeri proteklo vrijeme simulacije.

Simulacija diskretnih događaja namijenjena je razvoju modela koji detaljno opisuju strukturu sustava i njegove elemente, tj. oponašaju stvarne sustave i procese, te objekte iz stvarnog svijeta i njihovo međudjelovanje (Fishman, 2001., Banks i sur., 2010.). Najčešće se koristi za modeliranje i analizu sustava s čekanjima na resurse (npr. radno mjesto, transportno sredstvo, itd.) pri čemu su glavni elementi opisa:

- tijek procesa - prikazuje se strelicama koje povezuju entitete i odluke koje određuju smjer tijeka procesa,
- kapaciteti resursa - opisuju vrijeme potrebno resursu za izvršavanje određene aktivnosti (npr. stroj može obraditi jedinicu proizvoda za 5 minuta),
- ograničenja - opisuju raspoložive resurse (npr. 2 stroja ili 3 radnika, itd.).

Kod simulacije diskretnih događaja postoje dva tipa varijabli:

- nezavisne varijable (ulazne varijable) su varijable čije vrijednosti se upisuju u sustav, a to mogu biti: vrijeme između dolaska dva entiteta, vrijeme odvijanja pojedinog procesa

(vrijeme operacije, vrijeme transporta), broj raspoloživih resursa (broj strojeva, broj transportnih sredstava), organizacija čekanja (FIFO, prema prioritetu i slično.). Vrijednosti se često definiraju raspodjelama (Gaussova ili normalna raspodjela, trokutasta, uniformna itd.),

- zavisne varijable (izlazne varijable) su varijable čije vrijednosti se dobiju kao rezultat simulacije, a to mogu biti: broj entiteta u redu čekanja, vrijeme čekanja, iskorištenje resursa, propusnost sustava i slično.

3.4.1. Primjena simulacije diskretnih događaja

Složeni problemi planiranja redoslijeda u realnom okruženju sastoje se od mnogo ograničenja koji se ne smiju zanemariti. Pronalazak dobrog i primjenjivog rasporeda puno je važniji za proizvodna poduzeća nego pronalazak matematički optimalnog rješenja. Kao što je ranije rečeno, simulacija se primjenjuje u mnogim znanstvenim granama pa se tako sve više koristi i u proizvodnim okruženjima (Vaidyanathan i sur., 1998.). Stoga se simulacija realnih proizvodnih sustava koristi za analizu trenutnih proizvodnih sustava te za projektiranje novih proizvodnih sustava.

Kod analize rada postojećih sustava, simulacija se koristi za analizu učinkovitosti proizvodnih sustava (Wohlgemuth i sur., 2006.), određivanja slijeda narudžbi koji moraju biti ispunjeni (Dong i Medeiros, 2012.), iskorištenja proizvodnih kapaciteta (Kliment i sur., 2020.), propusnosti sustava tj. pronalaženja uskih grla (Langer i sur., 2009.), kao i raspoloživosti radnog osoblja (Yilmaz i sur., 2016.).

Međutim, proces pronalaska kvalitetnih rješenja samo uz pomoć simulacije često je dugotrajan. Za ubrzanjem tog procesa potrebno je uključiti neki od optimizacijskih alata.

Poglavlje 4: OPTIMALNO VREMENSKO ISKORIŠTENJE VLPS-a

Osnovni ciljevi svake proizvodnje su postizanje dovoljne kvalitete proizvoda uz što manje troškove proizvodnje, te isporuka na vrijeme (Schroeder, 1993.). U današnje vrijeme kada je izrazito važno zadržati stalne kupce i privući nove, upravo je isporuka na vrijeme osnovni uvjet koji treba biti zadovoljen. Ukoliko se roba ili usluga ne isporuči na vrijeme, osim dodatnih troškova u vidu „penala“ proizvodno poduzeće gubi i kredibilitet, a samim tim postaje nekonkurentno na tržištu.

Iz toga razloga, važno je planirati završetak proizvodnog procesa na vrijeme. To u pravilu znači da se dogovorena ukupna količina određenog proizvoda (ili više različitih vrsta proizvoda) mora proizvesti unutar nekog promatranog perioda, tj. vrijeme završetka izrade posljednje jedinice proizvoda mora biti manje od maksimalnog raspoloživog vremena proizvodnog sustava za promatrani period, prikazano izrazom 4.1. Pritom C_{max} predstavlja vrijeme završetka proizvodnje odnosno vrijeme kada je završena izrada na posljednjoj jedinici proizvoda i ukupna ugovorena proizvodna količina je spremna za isporuku. S druge strane, $C_{max,goal}$ označava maksimalno raspoloživo vrijeme proizvodnog sustava nakon kojeg sve ugovorene proizvodne količine moraju biti proizvedene. Drugim riječima, predstavlja rok isporuke. Maksimalno raspoloživo vrijeme za izradu ugovorenih količina izračunava se prema izrazu 4.2, kao

umnožak broja radnih dana, broja radnih smjena te trajanja pojedine smjene. U ovom radu, pronalazak najranijeg završetka proizvodnje predstavlja prvu funkciju cilja, izraz 4.3.

$$C_{max} < C_{max,goal} \quad (4.1.)$$

$$C_{max,goal} = d \cdot s \cdot h \quad (4.2.)$$

Gdje je: d - broj radnih dana u tjednu
 s - broj radnih smjena u danu
 h - broj radnih sati u smjeni

$$f_1 = \min(C_{max}) \quad (4.3.)$$

4.1. Ciklus izrade

Kod serijske proizvodnje u modelu VLPS-a proizvodi putuju u jediničnim serijama kroz sustav. Vrijeme koje provede određena jedinična serija proizvoda u procesu, od trenutka svog ulaska u sustav iz skladišta repromaterijala pa sve do izlaska iz sustava u skladište gotovih proizvoda, naziva se ciklus izrade.

U literaturi, ciklus izrade je jedna od najčešće optimiranih mjera uspješnosti. Ciklus izrade može se definirati kao ukupno vrijeme trajanja svih operacija kao i tehnički i organizacijski uvjetovanih prekida u vidu kontrole, transporta i međuskladištenja, pri proizvodnji jedinice proizvoda ili za određenu količinu s kojom se odjednom ulazi u proizvodnju. Tehnički i organizacijski uvjetovani prekidi često se nazivaju i međuoperacijska čekanja ili zastoji.

Ukratko, ciklus izrade sastoji se od vremena potrebnog za izvršenje svih operacija i vremena međuoperacijskih čekanja. Ukupno vrijeme potrebno za izvršenje svih operacija na jedinici proizvoda ili grupi proizvoda naziva se i tehnološki ciklus, kako slijedi:

$$t_{TC} = \sum_{i=1}^m o_i \quad (4.4)$$

gdje je: o_i - vrijeme i -te operacije, $i = 1, 2, 3, \dots, m$

Vrijeme međuoperacijskih čekanja je ono vrijeme u kojem se ne doprinosi kvalitativnim promjenama na proizvodu, odnosno u tom vremenu angažirana sredstva i izvršitelji ne daju nikakve proizvodne rezultate. Trajanje međuoperacijskih čekanja može varirati od nekoliko minuta do nekoliko dana (ovisno o kakvom čekanju se radi), ali se mogu odrediti. Međuoperacijska čekanja mogu se podijeliti u tri osnovne skupine:

- vrijeme kontrole, t_K
- vrijeme transporta, t_T
- vrijeme međuskladištenja, t_{MS} .

4.1.1. Vrijeme kontrole

Kontroliranje jedinice proizvoda iz pojedine jedinične serije je izrazito važno, jer se na taj način osigurava zadovoljavajuća i potrebna kvaliteta za isporučeni proizvod. Proizvodi se mogu kontrolirati u sklopu operacije i/ili nakon što je proizvod u potpunosti izrađen. Kontrola u sklopu operacije podrazumijeva da se nakon izrade u određenoj operaciji kontroliraju dobivene izmjere. Takav oblik kontrole se naziva i kontrolni zahvat. Ovdje je bitno naglasiti da je vrijeme kontrolnog zahvata sadržano unutar vremena zadane operacije. S druge strane, kako bi se osigurala dovoljna kvaliteta proizvoda na samom kraju proizvodnog procesa obavlja se i završna kontrola. Završna kontrola obavlja se zasebno te direktno utječe na vrijeme međuoperacijskih čekanja. Vrijeme ukupnog trajanja završne kontrole može se prikazati kao:

$$t_K = \sum_{k=1}^r k_k \quad (4.5.)$$

gdje je: k_k - vrijeme k -te kontrole, $k = 1, 2, 3, \dots, r$

4.1.2. Vrijeme transporta

Kako bi se osigurao prijenos jedinične serije proizvoda s jednog radnog mjesta na drugo radno mjesto potrebno je osigurati transport. Pritom, vrijeme transporta podrazumijeva vrijeme koje je određena jedinična serija proizvoda provela premještajući se s jednog radnog mjesta na drugo, uključujući dopremu iz skladišta repromaterijala na radno mjesto i otpremu s radnog mjesta u skladište gotovih proizvoda, izraz 4.6. Ukoliko su radna mjesta smještena blizu jedno drugom, osigurana je besprekidna (kontinuirana) proizvodnja. To u pravilu znači da transporta

nema (vrijeme transporta je jednako nuli), jer radnicima ili robotskim manipulatorima su izratci „na dohvata ruke“. Međutim, u ovom istraživanju to nije slučaj te vrijeme transporta predstavlja međuoperacijsko čekanje.

$$t_T = \sum_{l=1}^s t_l \quad (4.6.)$$

gdje je: t_l - vrijeme l -tog transporta, $l = 1, 2, 3, \dots, s$

Oblik transporta unutar proizvodnog pogona može biti raznolik. Vrsta transportnog sredstva se najčešće određuje ovisno o masi tereta koji se prenosi, u ovom slučaju jediničnih serija proizvoda. Prema tome, postoji nekoliko varijanti transportnih sredstava koja se koriste u proizvodnim poduzećima. Između ostalih, to su:

- radnik (do 20 kg) - ručno prenosi proizvode, npr. korištenjem kutije.
- konvejer (do 400 kg) - proizvodi se prenose putem automatizirane pokretne trake (i slično)
- viličar (više od 20 kg) - prenosi proizvode uz pomoć palete

Sve tri varijante transportnog sredstva imaju svoje prednosti. Gledano sa stajališta vremena, radnik će najprije prenijeti zadani teret s jednog mjesta na drugo, ali zato može prenijeti najmanju masu tereta. S druge strane, sa stajališta troška radnik je relativno skupa varijanta. Pogotovo kod varijante viličara, jer viličarem upravlja radnik. A to je onda najskuplja varijanta. S troškovnog stajališta konvejer je najisplativija varijanta. Međutim kod velikih masa jediničnih serija proizvoda, jedina moguća varijanta je viličar.

4.1.3. Vrijeme međuskladištenja

Međuskladištenje obuhvaća sva ona čekanja koje jedinica proizvoda provede čekajući na izradu (ispred radnog mjesta) zbog zauzetosti (nedostupnosti) proizvodnog kapaciteta, čekajući na transport (iza radnog mjesta) zbog zauzetosti (nedostupnosti) transportnog sredstva, te čekajući na red za izradu (pojedina radna mjesta u određenom vremenu sudjeluju u realiziranju više paralelnih procesa). Čekanje na izradu i čekanje na transport odnosi se na čekanje jedinične serije, dok se čekanje na red za izradu odnosi na jedinicu proizvoda. Čekanje na red za izradu podrazumijeva čekanje jedinice proizvoda iz određene jedinične serije da dođe na red za izradu

kao i čekanje da se preostale jedinice proizvoda iz iste jedinične serije izrade na tom radnom mjestu. Takav oblik čekanja je tipičan za proizvodnju u jediničnim serijama. Vrijeme međuskladištenja može se iskazati kao zbroj vremena svih čekanja jedinice proizvoda (jedinične serije proizvoda):

$$t_{MS} = \sum_{s=1}^t ms_s \quad (4.7.)$$

gdje je: ms_s - vrijeme s -tog međuskladištenja, $s = 1, 2, 3, \dots, t$

Slijedom navedenog, izrazom 4.8. može se prikazati izračun ciklusa izrade jednog izratka ili grupe izradaka kao:

$$t_{CI} = \sum_{i=1}^m o_i + \sum_{k=1}^r k_k + \sum_{l=1}^s t_l + \sum_{s=1}^t ms_s \quad (4.8)$$

Međutim, proizvodnju u realnom okruženju karakteriziraju određene nesigurnosti poput:

- kvara na proizvodnom kapacitetu,
- ili pojave škarta.

Takvi oblici nesigurnosti se pojavljuju slučajno te ne utječu jednako na pojedinu jediničnu seriju proizvoda. Prema tome, pojavom nesigurnosti povećava se vrijeme čekanja proizvoda određene jedinične serije, a samim time povećava se i ciklus izrade. Iz tog razloga, ciklus izrade definira se kao vrijeme koje jedinična serija j -tog proizvoda provede u procesu, odnosno razlika između vremena izlaska jedinične serije j -tog proizvoda iz sustava i ulaska jedinične serije proizvoda j u sustav (izraz 4.9.). Ciklus izrade određene jedinične serije j -tog proizvoda je različit zbog nejednolikih čekanja u procesu. Zbog jednostavnijeg daljnjeg optimiranja, prema izrazu 4.10., izračunava se njihova srednja vrijednost, t_{SCI} . Pritom je srednja vrijednost ciklusa izrade j -tog proizvoda $t_{SCI,j}$ zapravo prosječno vrijeme svih ciklusa izrade j -tog proizvoda.

$$t_{CI,j} = e_{bj} - r_{bj} \quad (4.9.)$$

$$t_{SCI,j} = \frac{\sum_1^{b_j} CI_j}{b_j} \quad (4.10.)$$

gdje je: e_{bj} - vrijeme izlaska b -te jedinične serije j -tog proizvoda iz procesa
 r_{bj} - vrijeme ulaska b -te jedinične serije j -tog proizvoda u proces
 b_j - broj jediničnih serija j -tog proizvoda

4.1.4. Vrijeme nepouzdanosti proizvodnog kapaciteta

Pouzdanost proizvodnog kapaciteta također je jako važan faktor u smanjenju trajanja proizvodnog procesa. Svaki proizvodni kapacitet u nekom trenutku ne radi zbog kvara. Kvar je najčešće lako i brzo otklonjiv ali ponekad traje puno duže. Međutim, ako su kvarovi većinom brzo otklonjivi, ali se događaju češće, vrijeme koje proizvodni kapacitet stoji (ne radi) i ne obrađuje proizvode uvelike raste. Stoga, nije svejedno da li m -ti proizvodni kapacitet ima pouzdanost $p_m = 0.8$ ili $p_m = 0.95$. Kako pouzdanost ovisi o proizvodnom kapacitetu, a ovo istraživanje se bavi poboljšanjem postojećeg stanja proizvodnog poduzeća, u ovom radu se neće razmatrati utjecaj veličine pouzdanosti proizvodnog kapaciteta, jer na taj parametar nije moguće direktno utjecati, osim ukoliko se razmatra opcija nabavke pouzdanijeg proizvodnog kapaciteta, a to nije predmet ovog istraživanja. Stoga se pouzdanost određenog proizvodnog kapaciteta procjenjuje i definira na temelju iskustva ili normativa. Vrijeme koje stroj ne radi zbog zastoja uzrokovanog njegovom nepouzdanosti računa se kao:

$$t_N = \sum_{u=1}^v brk_u \quad (4.11.)$$

gdje je: brk_u - vrijeme kada izradak (grupa izradaka) čeka obradu na nekom proizvodnom kapacitetu zbog zastoja uzrokovanog nepouzdanošću stroja, $u = 1, 2, 3, \dots, v$

4.1.5. Vrijeme izrade škarta

Škart je roba s greškom i događa se u nedefiniranim trenucima. Da škart nije poželjan je opće poznato, ali se događa te ga svakako treba uzeti u obzir. Vrijeme izrade škarta zapravo predstavlja vrijeme koje je jedinica proizvoda provela u procesu prije nego li je postala nevaljalom, odnosno škartom (izraz 4.12.). Direktno je vezano za vremena operacija, jer proizvodni kapaciteti su obrađivali jedinicu proizvoda koja se neće isporučiti. Pritom treba imati na umu da veći broj pojave škarta uzrokuje i rast vremena izrade škarta. Također, vrijedi

primijetiti da nije svejedno da li se greška dogodila na prvoj ili posljednjoj operaciji. Stoga, poželjno je osigurati da se u kasnijim fazama proizvodnje roba s greškom pojavljuje rjeđe nego na početku procesa. U realnoj proizvodnji se korištenjem stope pojave škarta p_s procjenjuje količina škartne robe koja će se dogoditi kako se nebi dogodio manjak potrebnih proizvodnih količina. Ta količina jedinica proizvoda obrađuje se prije početka proizvodnje, paralelno uz tekuću proizvodnju ili u sklopu tekuće proizvodnje.

$$t_s = \sum_{i=1}^m o_i, \quad \forall \quad j = \text{škarta} \quad (4.12.)$$

gdje je: o_i - vrijeme operacije škartnog proizvoda

4.1.6. Ostala vremena međuoperacijskih čekanja

Vrijeme međuskladištenja izrazito utječe na proizvodnost, odnosno na vremensko iskorištenje proizvodnog sustava. Na taj način utječe i na troškove proizvodnje. Utjecaj na troškove proizvodnje opisan je u poglavlju 4.5. Vrijeme međuskladištenja zapravo sadrži velik obim različitih oblika čekanja na koje vrijedi obratiti posebnu pozornost. Osim ranije opisanih nesigurnosti, na ukupno vrijeme međuskladištenja utječu vrijeme potrebno za pripremu i rasporedu radnog mjesta, vrijeme za zamjenu alata uslijed istrošenja oštrice i vremena čekanja na izradu ili transport i vremena čekanja na red za izradu. Vrijeme pripreme i rasporedu radnog mjesta t_{pz} objašnjeno je u zasebnom poglavlju. Stoga, preostaje objasniti vrijeme zamjene alata i vrijeme čekanja na izradu ili transport te vremena čekanja na red za izradu.

Svaki alat koji se koristi za izradu ima svoju trajnost oštrice. Trajnost oštrice ovisi o režimima rada koji se koriste. Definiranim režimima rada za korišteni alat, od strane tehnološke pripreme proizvodnje, proizlaze vremena zahvata. Zbrojem vremena zahvata u kojima se koristi određeni alat za određenu operaciju moguće je odrediti broj jedinica proizvoda nakon kojeg je određeni alat potrebno zamijeniti. Ukoliko se alat ne zamijeni na vrijeme uzrokovat će lošu kvalitetu izrade jedinice proizvoda te dovesti do škarta. Broj jedinica proizvoda nakon kojeg je potrebno izvršiti zamjenu alata neće se proračunavati nego će se procijeniti na temelju iskustvenih podataka dobivenih od proizvodnog poduzeća iz realnog sektora. Vrijeme potrebno za zamjenu alata definira se na temelju normativa (uniformna razdioba) ili iskustva (normalna razdioba). Dok se obavlja zamjena alata, proizvodni kapacitet ne radi, a proizvodi čekaju na izradu. Stoga

je potrebno izračunati vrijeme zamjene alata prema izrazu 4.13. Ovdje je bitno naglasiti da se ovo vrijeme ne odnosi na vrijeme zamjene alata prilikom pripreme i raspoređivanja radnog mjesta.

$$t_{ZA} = \sum_{a=1}^f za_a \quad (4.13.)$$

gdje je: za_a - vrijeme zamjene a -tog alata, $a = 1, 2, 3, \dots, f$

Tijekom procesa proizvodnje proizvodi čekaju na izradu, čekaju na red za izradu ili čekaju na transport. Pod čekanjem na izradu smatraju se sva ona vremena na ulaznom međuskladištu u kojem određena jedinična serija proizvoda čeka na izradu na određenom proizvodnom kapacitetu, odnosno radnom mjestu. Kada određena jedinična serija dođe na svoj red za izradu, jedinice proizvoda iz te jedinične serije čekaju da se izvrši operacija na svim jedinicama proizvoda. Pritom, svaka jedinica proizvoda čeka red na izradu, a nakon što se na njoj izvede operacija, tada čeka preostale jedinice proizvoda da i one završe s izradom na tom radnom mjestu. Nakon toga, jedinična serija proizvoda čeka na transportno sredstvo kojim će se premijestiti u sljedeću fazu proizvodnje. Ovo vrijeme je ovisno o dostupnosti transportnog sredstva. Vremena čekanja na izradu i čekanja na transport te čekanja na red za izradu opisana su kako slijedi:

$$t_{\check{c}} = \sum_{f=1}^k \check{c}_f + \sum_{g=1}^l \check{c}_g + \sum_{h=1}^m \check{c}_h \quad (4.14.)$$

gdje je: $\check{c}_f$ - vrijeme koje jedinična serija proizvoda provede čekajući na izradu, $f = 1, 2, 3, \dots, k$

$\check{c}_g$ - vrijeme koje jedinična serija proizvoda provede čekajući na transportno sredstvo, $g = 1, 2, 3, \dots, l$

$\check{c}_h$ - vrijeme koje jedinice proizvoda određene jedinične serije proizvoda provedu čekajući na red za izradu, $h = 1, 2, 3, \dots, m$

Sukladno svemu navedenom, uvrštavanjem u izraz 4.8. formirat će se novi prošireni izraz koji će se koristiti za izračun ciklusa izrade, kako slijedi:

$$t_{CI} = t_{TC} + t_K + t_T + t_{PZ} + t_{ZA} + t_N + t_{\xi} + t_{\check{c}} \quad (4.15.)$$

4.2. Pripremno-završno vrijeme

Za izvođenje nekog proizvodnog zadatka, tj. operacije potrebno je obaviti pripremu radnog mjesta, a po završetku raspremu (Nicholas, 2008.). Za vrijeme izvođenja pripreme i raspreme radnog mjesta proizvodni kapacitet ne radi. Priprema i rasprega radnog mjesta je aktivnost koja je nezaobilazna u funkciji obavljanja proizvodnog zadatka, ali blokira određeno vrijeme odvijanje proizvodnje na radnom mjestu za određen vremenski period, što predstavlja gubitak dijela kapaciteta proizvodnog kapaciteta. Taj gubitak je izrazito osjetljiv na radnim mjestima s čestom promjenom operacija, a to je posebno izraženo kod proizvodnje većeg asortimana proizvoda. Ukratko rečeno, pripremno-završno vrijeme je vrijeme potrebno radniku da osigura radno mjesto za nesmetan rad. Pripremno-završno vrijeme još se naziva i pripremno-raspremno vrijeme.

Aktivnosti pripreme i raspreme radnog mjesta između ostalih uključuju:

- upoznavanje sa zadatkom,
- preuzimanje i dopremu alata iz skladišta alata do radnog mjesta,
- preuzimanje i dopremu radne naprave/steznog pribora do radnog mjesta,
- postavljanje alata, odnosno radne naprave/steznog pribora na stroj,
- umjeravanje alata i izratka,
- probni rez i provjeru prvog izratka,
- skidanje i čišćenje alata, radne naprave/steznog pribora sa stroja,
- otprema alata i radne naprave/steznog pribora u skladište.

Pripremno-završno vrijeme nije jednoliko za svaku operaciju odnosno za svako radno mjesto. S jedne strane, razlog leži u tome da različita proizvodna oprema iziskuje različito pripremno-završno vrijeme. Jednostavnije strojeve (strojna pila) je puno brže pripremiti za obradu nego složenije strojeve (obradni centar). S druge strane, nerealno je očekivati kako će se priprema/rasprega radnog mjesta obaviti svaki puta za isto utrošeno vrijeme. Postavlja se pitanje zašto se pripremno-završno vrijeme ne može jednoznačno prikazati? Razloga je više. Između ostalih, radno osoblje koje obavlja pripremu-raspremu radnog mjesta je različito (rad u više smjena), umor i motiviranost radnog osoblja, itd.

Matematičkim jednadžbama je gotovo nemoguće opisati nejednolikost pripremno-završnog vremena, stoga se ono prikazuje kao jednoznačna vrijednost. Tako prikazano uvelike utječe na

odvijanje drugih događaja, pogotovo ako će se matematički model usporediti s proizvodnjom u realnom svijetu. Vrijeme početka i završetka određenih događaja (aktivnosti) puno češće će se razlikovati. Upotrebom simulacije, nejednolikost pripremno-završnog vremena se može uključiti. Takav scenarij rezultirat će puno većom sličnošću modela s proizvodnjom u stvarnom svijetu. Shodno tome, vrijednost pripremno-završnog vremena procjenjuje se i određuje se na dva načina, na temelju:

- normativa (uniformne razdiobe),
- iskustva (normalna razdioba).

U znanstvenoj literaturi se češće pojavljuje zastupljenost procjene na temelju normativa (Sharma i Jain, 2015.), dok se u praksi procjenjuje na temelju iskustva. Koliko je vremena određeno radno mjesto, odnosno proizvodni kapacitet bio zauzet aktivnostima pripreme i raspeme, određuje se prema izrazu 4.16. S druge strane, izrazom 4.17., može se odrediti ukupno vrijeme koje je jedinična serija j -tog proizvoda provela čekajući na pripremu i raspemu radnog mjesta.

$$t_{PZ} = \sum_{m=1}^o pZ_m \quad (4.16.)$$

$$t_{UPZ,j} = \sum_{j=1}^n \sum_{m=1}^o pZ_{mj} \quad (4.17.)$$

gdje je: pZ_m - pripremno-završno vrijeme m -tog proizvodnog kapaciteta,
 $m = 1, 2, 3, \dots, o$

$t_{UPZ,j}$ - ukupno pripremno-završno vrijeme j -tog proizvoda

pZ_{mj} - pripremno-završno vrijeme j -tog proizvoda na m -tom proizvodnom kapacitetu, $j = 1, 2, 3, \dots, n$ i $m = 1, 2, 3, \dots, o$

4.3. Utjecaj redoslijeda i veličine jedinične serije na ciklus izrade i pripremno-završno vrijeme


Proizvodnju u jediničnim serijama, između ostalog, karakterizira da za vrijeme dok se jedinica proizvoda iz određene jedinične serije obrađuje na nekom proizvodnom kapacitetu, ostale

jedinice proizvoda iz te jedinične serije čekaju na red za izradu te se tek po završetku izrade svih jedinica proizvoda jedinična serija prenosi na sljedeću radnu stanicu. Ako se pretpostavi da je vrijeme kontrole sadržano u vremenu operacije i da je vrijeme operacije jednako za svaki proizvod te da se zanemaruje utjecaj nesigurnosti, onda je i vrijeme međuskladištenja kao i vrijeme transporta jednako za svaku jedinicu proizvoda. Prema tome može se zaključiti da ovisno o broju jedinica proizvoda u određenoj jediničnoj seriji ovisi ciklus izrade te jedinične serije. Drugim riječima, povećanjem veličine jedinične serije će se povećati i ciklus izrade, odnosno smanjenjem veličine jedinične serije će se smanjiti i ciklus izrade. Pojašnjeno slikom 4.1. Veličina jedinične serije izravno utječe i na vrijeme završetka proizvodnje pa tako manja veličina jedinične serije pretpostavlja kraće vrijeme završetka proizvodnje. Vrijedi i obratno.

Slučaj 1)

Ukupna količina: 200 kom Veličina serije: 100 kom


Vrijeme operacije (na svakom stroju): 1 min



Slučaj 2)

Ukupna količina: 200 kom Veličina serije: 50 kom

Vrijeme operacije (na svakom stroju): 1 min



Slika 4.1. Utjecaj veličine jedinične serije na vrijeme trajanja proizvodnje

Uključivanjem nesigurnosti kao i utjecaja nejednolikog trajanja pripreme i raspoređivanja radnog mjesta, može se dogoditi da za iste parametre procesa jedinična serija s manjim brojem jedinica proizvoda ima veći ciklus izrade od jedinične serije s većim brojem jedinica proizvoda. Iako je vjerojatnost takvog scenarija izrazito mala, da bi se izbjegao utjecaj takvih mogućnosti za mjeru uspješnosti će se promatrati srednja vrijednost ciklusa izrade. Promatrajući utjecaj veličine jedinične serije na srednji ciklus izrade određenog proizvoda, i dalje vrijedi isti zaključak. A to je da povećanjem veličine jedinične serije se povećava i vrijeme koje jedinična serija proizvoda provede u procesu, tj. srednji ciklus izrade. Isto vrijedi i za vrijeme završetka proizvodnje.

S druge strane, redoslijed ulaska jediničnih serija proizvoda ima izrazito velik utjecaj na vrijednost ciklusa izrade pojedine jedinične serije proizvoda kao i na vrijednost srednjeg ciklusa izrade određene vrste proizvoda, slika 4.2.

Prilikom ulaska različitih jediničnih serija proizvoda jedna za drugom, pojavljuje se potreba za pripremom i raspoređivanjem radnog mjesta. Kada je određena jedinična serija nekog proizvoda završena na određenom proizvodnom kapacitetu tada na isti proizvodni kapacitet dolazi nova jedinična serija proizvoda. Ukoliko je nova jedinična serija proizvoda ista kao i prethodna jedinična serija proizvoda, tada nije potrebno pripremno-završno vrijeme, odnosno pripremno-završno vrijeme je jednako nuli. U suprotnom, ako je nova jedinična serija proizvoda različita od prethodne jedinične serije proizvoda onda se prije početka obrade vrši priprema-raspoređivanje radnog mjesta. Također, prilikom dolaska prve jedinične serije proizvoda na određeni proizvodni kapacitet isto se provodi priprema i raspoređivanje radnog mjesta. Stoga, poželjno je da se jedinične serije istovrsnih proizvoda obrađuju jedna za drugom kako bi se smanjilo pripremno-završno vrijeme.

Kod proizvodnje više različitih proizvoda nejednolikost pripremno-završnog vremena može ovisiti i o slijedu proizvoda koji dolaze na određeno radno mjesto. Primjerice, ako se proizvod A obrađuje nakon proizvoda B na istom proizvodnom kapacitetu, tada pripremno-završno vrijeme može biti puno veće nego kada se proizvod B obrađuje nakon proizvoda A (Dong i Medeiros, 2012.).


Slijedom navedenog, može se zaključiti da redoslijed ulaska jediničnih serija proizvoda ima izrazit utjecaj na pripremno-završno vrijeme, za razliku od veličine jediničnih serija koja sama po sebi nema utjecaja. Međutim, kako je promatrana proizvodnja većeg broja različitih proizvoda veličina jediničnih serija u kombinaciji s redoslijedom ulaska proizvoda značajno

doprinosi različitim vrijednostima pripremno-završnog vremena. Odnosno, veći broj jediničnih serija uvjetovat će većim ukupnim pripremno-završnim vremenom.


Proizvod A: Ukupna količina: 20 kom
Veličina serije: 10 kom
Vrijeme svake operacije: 1 min

Proizvod B: Ukupna količina: 20 kom
Veličina serije: 10 kom
Vrijeme svake operacije: 2 min

Slučaj 1 (A-A-B-B)



Slučaj 2 (A-B-A-B)



Slika 4.2. Utjecaj redoslijeda ulaska različitih jediničnih serija na vrijeme trajanja proizvodnje

Na kraju se iz svega navedenog može zaključiti da gledajući sa stajališta minimalnog pripremno-završnog vremena idealno bi bilo kada bi se proizvodnja u VLPS-u odvijala koristeći što veću veličinu jedinične serije. Isto tako gledajući sa stajališta minimalne srednje vrijednosti

ciklusa izrade, poželjno je da se proizvodnja odvija koristeći što manju veličinu jedinične serije proizvoda, što dovodi do kontradiktornosti.

Iz tog razloga potrebno je pronaći one vrijednosti veličine jediničnih serija i redoslijeda ulaska jediničnih serija proizvoda kako bi se odredilo optimalno vremensko iskorištenje VLPS-a s ciljem minimiziranja srednjeg ciklusa izrade i ukupnog pripremno-završnog vremena. Pritom je potrebno zadovoljiti osnovni uvjet isporuke na vrijeme. Navedeno predstavlja drugu funkciju cilja kojoj se teži u ovom istraživanju, prema navedenom izrazu:

$$f_2 = \min \left(\sum_{j=1}^n t_{SCI,j} + \sum_{j=1}^n t_{UPZ,j} \right) \quad (4.18.)$$

4.4. Formulacija troškova proizvodnje

Vrijeme je izrazito važna veličina za proizvodnju. Pogotovo sa stajališta konkurentnosti na tržištu, jer je izrazito važno isporučiti robu ili uslugu na vrijeme. Međutim, vrijeme nije relevantna veličina koja će pokazati hoće li proizvodno poduzeće uspješno poslovati, odnosno egzistirati. Veličina kroz koju treba promatrati proizvodnju je nekakva novčana vrijednost (bilo da se radi o kunama, eurima, dolarima ili sličnom). Svakog poslodavca na kraju najviše zanimaju ti podaci.

Često se u svijetu može čuti izreka „Vrijeme je novac“. Međutim, u proizvodnji nisu sva vremena jednako vrednovana. Može se slobodno reći da neka vremena predstavljaju veći trošak nego druga, npr. sat rada tokarskog obradnog centra je puno skuplji od sata rada obične CNC tokarilice, jer je tokarski obradni centar puno skuplji prilikom kupovine odnosno ima puno veću vrijednost.

Sva vremena u proizvodnji se u nekom obliku mogu prikazati kao trošak. U procesu trošenja dugotrajna imovina prenosi dio svoje vrijednosti na proizvode, zato se amortizacija računa kao trošak dobivenog proizvoda i zaračunava se u njegovu cijenu koštanja. Taj proces trošenja se svodi na postupak postupnog smanjivanja vrijednosti neke imovine (proizvodni kapaciteti, transportna sredstva, itd.) i njezina svođenja na nulu. Gledajući kroz prizmu vremenske amortizacije koja se utvrđuje na osnovici procjenjenog vijeka trajanja imovine (npr. 10 godina), sva proizvodna oprema i transportna sredstva će kroz svoju amortizacijsku vrijednost

povećavati trošak proizvodnje. Amortizacijska vrijednost će se promatrati pravolinijski tj. bit će ravnomjerno raspoređena kroz sve godine (www.enciklopedija.hr). Ono što karakterizira svaku proizvodnju je osigurati isporuku na vrijeme uz najmanje moguće troškove proizvodnje. To znači da nije nužno proizvesti zadane količine u najkraćem mogućem vremenu, nego da su utrošena novčana sredstva što manja. Prema tome, izrazom 4.19., formuliran je ukupni trošak proizvodnje (UTP). Čine ga trošak proizvodne opreme, trošak alata, trošak škarta, trošak skladištenja, trošak energije, trošak repromaterijala i trošak zakašnjele isporuke. Trošak proizvodnje predstavlja treću funkciju cilja koja se optimira u ovom istraživanju, izraz 4.20. Pronalaženjem minimalnih troškova proizvodnje uz osnovni uvjet pravovremene isporuke odredit će optimalno vremensko iskorištenje VLPS-a.

$$UTP = (T_{PO} + T_A + T_{\xi} + T_S + T_E + T_{RPM}) \cdot (1 + k_{PEN}) \quad (4.19.)$$

$$f_3 = \min(UTP) \quad (4.20.)$$

4.4.1. Trošak proizvodne opreme

Kod serijske proizvodnje u VLPS-u, proizvodna oprema se koristi samo za navedeni proizvodni proces što znači da proizvodna oprema predstavlja trošak sve vrijeme dok traje proizvodnja, odnosno za promatrano razdoblje. Sastoji se od strojeva, transportnih sredstava i kontrolne opreme te se u promatranom razdoblju koristi kao resurs aktivno i pasivno. Aktivno iskorištenje strojeva vezano je za vrijeme izvođenja operacija, dok se pasivno iskorištenje strojeva odnosi na međuoperacijska čekanja, i to na pripremu i rasporedu radnog mjesta, zamjenu alata, zastoje zbog kvara (nepouzdanosti), čekanja proizvoda na izradu, čekanja na red za izradu i čekanja na transport, ali i vremena čekanja kada strojevi ne rade jer su svi proizvodi izrađeni. Kontrolna oprema se aktivno koristi prilikom završne kontrole, a pasivno za čekanje na kontrolu sljedećeg proizvoda. Aktivno iskorištenje transportnog sredstva odnosi se na vrijeme dok se prenose proizvodi, dok ostalo vrijeme transportno sredstvo miruje. Trošak proizvodne opreme dan je izrazom 4.21., gdje je t_{max} vrijeme završetka promatranog razdoblja (može poprimiti vrijednosti C_{max} ili $C_{max,goal}$), a AV_m , AV_k i AV_l predstavljaju amortizacijske vrijednosti m -tog stroja, k -te kontrolne opreme i l -tog transportnog sredstva.

$$T_{PO} = t_{max} \cdot \left(\sum_{m=1}^o AV_m + \sum_{k=1}^p AV_k + \sum_{l=1}^r AV_l \right) \quad (4.21.)$$

4.4.2. Trošak alata

Trošak alata ovisan je o broju korištenih alata za potrebe izvođenja operacija na svim jediničnim serijama proizvoda. Izračunava se prema izrazu 4.22., kao umnožak ukupnog broja i cijene koštanja utrošenih alata a kroz promatrano razdoblje na m -tom proizvodnom kapacitetu. Ovdje je bitno naglasiti da su u ukupnom broju utrošenih alata sadržani alati utrošeni za vrijeme pripreme i raspoređivanja radnog mjesta kao i za vrijeme zamjene alata uslijed istrošenosti.

$$T_A = \sum_{m=1}^o \sum_{a=1}^q N_{am} \cdot T_{am} \quad (4.22.)$$

gdje je: N_{am} - broj utrošenih alata a na m -tom proizvodnom kapacitetu

T_{am} - cijena koštanja alata a korištenog na m -tom proizvodnom kapacitetu

4.4.3. Trošak škarta

Pojava škarta može višestruko utjecati na povećanje ukupnog troška. To se odnosi na dodatno zauzeće strojeva i moguće povećanje broja utrošenih alata. Također, pojava škarta produljuje odvijanje procesa, a to može dovesti do zakašnjele isporuke. Navedeni utjecaji rezultiraju troškovima koji su zadržani u trošku proizvodne opreme, trošku alata i trošku zakašnjele isporuke. Međutim, pojava škarta utječe i na povećanje potrebne količine repromaterijala. Stoga, trošak škarta je umnožak količine škartnih jedinica proizvoda $\check{s}_{ij}$ i cijene repromaterijala $T_{rpm,j}$, a računa se kako slijedi:

$$T_{\check{s}} = \sum_{j=1}^n \sum_{m=1}^o \check{s}_{ij} \cdot T_{rpm,j} , \quad \forall \quad j = \text{škarta} \quad (4.23.)$$

4.4.4. Trošak skladištenja

Jedan od najvažnijih troškova na koji se mora obratiti pozornost je trošak skladištenja. Ovisno o proizvodnim količinama i dimenzijama proizvoda (repromaterijala, gotovog proizvoda), kao i njegove vrijednosti, taj trošak ima veći ili manji značaj. Nije poželjno da proizvod stoji na skladištu. Filozofija JIT (engl. *Just In Time*) govori da je idealno kada bi se roba ili usluga isporučila točno na vrijeme. Međutim, u stvarnosti je to izrazito riskantno i praktično nemoguće

postići, ali se tome teži. Pritom valja naglasiti kako nije jednaka cijena skladištenja repromaterijala i skladištenja gotovih proizvoda. Stoga, poželjno je da gotovi proizvodi što manje stoje na skladištu gotovih proizvoda, jer imaju relativno veliku vrijednost. S druge strane, kako ulazni materijal ne bi dugo stajao u skladištu repromaterijala može se osigurati dobava materijala u nekoliko intervala. Trošak skladištenja T_S može se podijeliti na dva dijela (4.24.), na trošak skladištenja repromaterijala (4.25.), i trošak skladištenja gotovih proizvoda (4.26.).

$$T_S = T_{SRM} + T_{SGP} \quad (4.24.)$$

$$T_{SRM} = \sum_{j=1}^n \sum_{b=1}^h (r_{bj} - t_0) \cdot Lot_j \cdot T_{srm,j} \quad (4.25.)$$

$$T_{SGP} = \sum_{j=1}^n \sum_{b=1}^h (t_{max} - e_{bj}) \cdot Lot_j \cdot T_{sgp,j} \quad (4.26.)$$

Trošak skladištenja repromaterijala može se prikazati kao vrijeme koje ulazni materijal (repromaterijal) provede u skladištu repromaterijala pomnoženo s cijenom skladištenja repromaterijala, dok trošak skladištenja gotovih proizvoda predstavlja umnožak vremena koje gotov proizvod provede na skladištu gotovih proizvoda i cijene skladištenja gotovog proizvoda. Pritom je r_{bj} vrijeme ulaska b -te jedinične serije j -tog proizvoda u proizvodni proces (izlaska iz skladišta repromaterijala), t_0 vrijeme početka proizvodnje (nulto vrijeme), Lot_j veličina jedinične serije j -tog proizvoda, $T_{srm,j}$ cijena skladištenja jedinice j -tog ulaznog materijala, dok t_{max} predstavlja vrijeme završetka promatranog razdoblja (može poprimiti vrijednosti C_{max} i $C_{max,goal}$), e_{bj} vrijeme ulaska b -te jedinične serije j -tog proizvoda u skladište gotovih proizvoda, a $T_{sgp,j}$ cijenu skladištenja jedinice j -tog gotovog proizvoda.

4.4.5. Trošak energije

Pod pojmom troška energije podrazumijeva se koliko je energije utrošeno za odvijanje proizvodnog procesa u promatranom vremenskom razdoblju. Prvenstveno se to odnosi na potrošnju električne energije, jer su strojevi, kontrolna oprema i transportna sredstva najčešće pogonjeni na struju te se tako i promatraju. Pritom treba voditi računa da potrošnja energije nije ravnomjerna (pokretanje proizvodne opreme, nesmetan rad, stanje mirovanja i dr.). Trošak

energije T_E jednak je umnošku potrošene električne energije strojeva E_m , kontrolne opreme E_k i transportnog sredstva E_l te cijene električne energije T_e , kako slijedi:

$$T_E = \left(\sum_{m=1}^o E_m + \sum_{k=1}^r E_k + \sum_{l=1}^s E_l \right) \cdot T_e \quad (4.27.)$$

gdje je: E_m - količina utrošene energije na m -tom proizvodnom kapacitetu, $m = 1, 2, \dots, o$

E_k - količina utrošene energije na k -toj kontrolnoj opremi, $k = 1, 2, \dots, r$

E_l - količina utrošene energije na l -tom transportnom sredstvu, $l = 1, 2, \dots, s$

T_e - cijena koštanja jedinične električne energije

4.4.6. Trošak repromaterijala

Također, u trošak proizvodnje treba ubrojiti i trošak repromaterijala odnosno kolika je cijena ulaznog materijala (poluproizvoda). Trošak repromaterijala T_{RPM} (4.28.) ogleda se kao produkt proizvodne količine q_j i cijene koštanja j -tog ulaznog materijala $T_{rpm,j}$. Cijena repromaterijala može varirati zbog nestalnosti tržišnih cijena, odnosno u kojoj količini i od kojeg dobavljača se repromaterijal nabavlja. Taj utjecaj nestalnosti cijene repromaterijala neće se uzeti u obzir u ovom radu nego se promatra kao fiksna veličina.

$$T_{RPM} = \sum_{j=1}^n q_j \cdot T_{rpm,j} \quad (4.28.)$$

4.4.7. Trošak zakašnjele isporuke

Posljednji i najnepovoljniji trošak koji se pojavljuje je trošak uslijed kašnjenja isporuke ugovorenih proizvodnih količina, jer osim što povećava trošak proizvodnje, on negativno utječe i na konkurentnost proizvodnog poduzeća. Trošak kašnjenja isporuke odnosno tzv. penali su trošak koji se nadodaje na ukupni trošak proizvodnje u obliku postotnog iznosa na ukupnu vrijednost zakašnjelo isporučene robe. Prikazuje se kao koeficijent zakašnjele isporuke, k_{PEN} . Pritom valja napomenuti da je $k_{PEN} = 1$, ukoliko je ugovorena proizvodna količina isporučena

na vrijeme. Ukoliko isporuka ugovorene proizvodne količine kasni, tada se koeficijent zakašnjele isporuke računa kao:

$$k_{PEN} = (C_{max} - C_{max,goal}) \cdot P_j \quad \forall \quad (C_{max} - C_{max,goal}) > 0 \quad (4.29.)$$

Vrijedi napomenuti da P_j predstavlja stopu penala za neisporuku j -tog proizvoda. Stopa penala za isporuku ovisi o ugovorenim uvjetima između naručitelja i proizvodnog poduzeća.

Poglavlje 5: SIMULACIJSKI OKVIR


Na temelju istražene literature može se primijetiti da postojeći alati i metode daju određena rješenja ali zbog mnogih pojednostavljenja ostavljaju prostor za daljnji napredak i razvoj novih, poboljšanih metoda. Razloga je mnogo, jer neke metode nisu primjenjive za kompleksnije sustave i veće obime proizvodnje, mnoge su spore i neučinkovite, ili su neprikladne za operativno upravljanje proizvodnjom.

Stoga, zbog svoje sposobnosti analiziranja postojećeg stanja i eksperimentalnih istraživanja na stvarnom proizvodnom sustavu bez ometanja rada stvarnog sustava, simulacija diskretnih događaja pokazala se kao odlično rješenje za probleme pri planiranju proizvodnje. Međutim, ako ne najveći onda jedan od najvećih nedostataka simulacije je taj što simulacija sama po sebi ne služi kao tehnika optimizacije (Montevecchi i sur., 2012.).

Na taj način su korisnici simulacija prisiljeni simulirati više konfiguracija sustava te odabrati onaj sustav koji daje najbolje performanse, što je često vrlo iscrpno. Razvoj računala uvelike je pomogao izmijeniti ovaj slučaj zbog sve veće dostupnosti bržih računala i sve boljih tehnika pretraživanja i heurističke optimizacije.

Simulacijski model općenito uključuje η ulaznih varijabli $(x_1, x_2, \dots, x_\eta)$ i θ izlaznih varijabli $(y_1, y_2, \dots, y_\theta)$, slika 5.1. Optimiranje neke simulacijske metode podrazumijeva pronalaženje

optimalne konfiguracije ulaznih varijabli, tj. vrijednosti $x_1, x_2, \dots, x_n$ koje optimiraju funkciju cilja (Carson i Maria, 1997.).



Slika 5.1. Shema simulacijskog modela (Carson i Maria, 1997.)

Kombinacija simulacijskih metoda s metodama optimizacije prepoznata je kao obećavajuće rješenje. U novijoj literaturi može se pronaći sve veći broj istraživanja koji povezuju simulacijske metode i metode optimizacije za rješavanje složenih kombinatornih problema (Caggiano i sur., 2015., Ištoković i sur., 2019.a).

5.1. Simulacijsko-optimizacijski pristup

Simulacijsko-optimizacijski pristup može se definirati kao postupak ispitivanja različitih kombinacija vrijednosti s ciljem pronalaska onih kombinacija vrijednosti koje daju najpoželjniji izlazni rezultat za simulacijske modele (Montevecchi i sur., 2012). Iako je simulacija poznata pola stoljeća, znanstvena zajednica nije bila voljna koristiti optimizacijske alate u simulaciji sve do kraja 20. stoljeća kada se prvi put pojavljuju dvije knjige o simulacijama (Law i Kelton, 2000., Banks i sur., 2010.). Upotrebom metaheurističkih istraživanja sve više se koriste optimizacijski alati i u simulacijama (April i sur., 2006.).

Autori (Azadeh i sur., 2010.) navode da je kombinacija simulacije i optimizacije jedna je od najvažnijih tehnika koja se pojavljuje posljednjih godina. Ovi autori napominju da su prethodne metodologije zahtijevale provođenje složenih promjena simulacijskog modela, te su na taj način trošile vrijeme i računalni potencijal, a u mnogim slučajevima čak i nisu bile ekonomski isplative za stvarne slučajeve zbog velikog broja varijabli odlučivanja.

U prilog simulacijsko-optimizacijskom pristupu ide i to što autori (Andradottir, 1998., Harrell i sur., 2004.) tvrde da se upotreba optimizacije sa simulacijom kontinuirano povećava zbog pojave simulacijskih paketa koji posjeduju integrirane optimizacijske alate. Ideja zašto uključiti

optimizacijske alate unutar simulacije je traženje poboljšanih definicija za parametre sustava u odnosu na njegove performanse. Međutim, problem predstavlja što na kraju optimizacije korisnik ne može znati je li postignut optimum. U realnoj proizvodnji taj problem ne predstavlja veliki problem jer su dobivena optimalna rješenja često dovoljna za poboljšanje učinkovitosti sustava.

Provjera performansi sustava korištenjem simulacije za određeni skup parametara sustava s razumnom preciznošću zahtjeva znatan računalni potencijal. Pronalazak optimalnog ili skoro optimalnog rješenja iziskuje provjeru velikog broja vrijednosti parametara tako da je optimizacija u sklopu simulacije u pravilu vrlo iscrpna. Usprkos razvoju softvera za optimizaciju unutar simulacije, prilikom manipulacije više od jedne varijable postaje vrlo spor (Andradottir, 1998.).

5.1.1. Programski paketi za simulacijsko-optimizacijski pristup

Glavni programski paketi za simulacijsko-optimizacijski pristup koji se nalaze na tržištu a navode se i u akademskoj literaturi prikazani su tablicom 5.1. Također, prikazane su i tehnike optimizacije koje se mogu koristiti u svakom od navedenih programskih paketa. Različiti programski paketi koriste različite metode pretraživanja, kao što su: evolucijski algoritmi, genetski algoritmi, tabu pretraživanje, neuronske mreže i simulirano kaljenje.

Tablica 5.1. *Simulacijski programski paketi s korištenim optimizacijskim alatima*

Simulacijski paket	Optimizacijski alat
AutoMod®	Evolucijski i genetski algoritam
Arena®	Tabu pretraživanje i neuronske mreže
Simul8®	Neuronske mreže
Witness®	Simulacijsko žarenje i tabu pretraživanje
Tecnomatix Plant Simulation®	Genetski algoritam i neuronske mreže

Programski alati za simulacijsko modeliranje imaju svoje prednosti i nedostatke. Zbog toga je potrebno odabrati odgovarajući programski alat kako bi se maksimizirale prednosti korištenja prilikom izrade modela. Ovakvi programski paketi kroz digitalne modele omogućuju

pokretanje eksperimenata i scenarija bez narušavanja postojećih proizvodnih sustava. Također, koriste se u procesu planiranja novih proizvodnih sustava. Velik broj alata za analizu kroz statistike i grafikone omogućava procjenu različitih scenarija proizvodnje. Rezultati pružaju informacije potrebne za brzu, pouzdanu i pametniju odluku u ranoj fazi planiranja proizvodnje (Winston i Goldberg, 2004.).


Jedan od takvih programskih alata je i Tecnomatix Plant Simulation, tvrtke Siemens. Tecnomatix Plant Simulation alat je za simulaciju diskretnih događaja koji pomaže u izradi digitalnih modela logističkih sustava, kao što je proizvodnja, što omogućava istraživanje karakteristika sustava i optimizaciju njegove učinkovitosti. Pomoću programskog paketa Tecnomatix Plant Simulation može se modelirati i simulirati proizvodne sustave i njihove procese. Osim toga, može se optimizirati tijekom materijala, iskoristivost resursa i logistiku za sve razine planiranja, od globalnih proizvodnih postrojenja, preko lokalnih postrojenja, do određenih proizvodnih linija (Bangsow, 2020.). Svjetski je lider u 3D logističkom modeliranju. Koristi se sa Windows operacijskim sustavima i može koristiti drugi softver za obavljanje specijaliziranih funkcija kao što su Matlab, MS-Excel, SAP, Simatic IT, Teamcenter, Autocad, Microstation.

5.2. Simulacijski okvir za određivanje optimalnog vremenskog iskorištenja

U ovom radu svrha istraživanja je integrirati alate za simulaciju i optimizaciju kako bi se iskoristile prednosti oba alata. S jedne strane, simulacija diskretnih događaja omogućava izradu digitalnog modela stvarnog proizvodnog sustava te analizu postojećeg stanja bez ometanja rada stvarnog sustava. Osim toga, osigurava uključivanje brojnih nesigurnosti karakteričnih za stvarne proizvodne sustave, npr. kvar na stroju, škart, čekanja, itd. S druge strane, optimizacijski alat genetski algoritam osigurava mogućnost pronalaska optimalnih (ili gotovo optimalnih) rješenja.

Primjena takvog simulacijsko-optimizacijskog pristupa za rješavanje problema planiranja redoslijeda i planiranja veličine jediničnih serija proizvoda dana je kroz simulacijski okvir, slika 5.2. Simulacijski okvir omogućava određivanje redoslijeda ulaska jediničnih serija proizvoda u sustav te veličine jedinične serije proizvoda s ciljem zadovoljenja nekih od postavljenih ciljeva, a samim time omogućava određivanje optimalnog vremenskog iskorištenja proizvodnog sustava.

Simulacijski okvir zapravo predstavlja simulaciju diskretnih događaja unutar koje je implementiran optimizacijski alat genetski algoritam. Kao i kod svake simulacije diskretnih događaja, na početku je potrebno izraditi simulacijski model promatranog sustava na temelju prikupljenih podataka o radu sustava te problemu razmatranja.



Slika 5.2. Simulacijski okvir za određivanje optimalnoga vremenskog iskorištenja

Broj ponavljanja simulacijskih eksperimenata na takvom simulacijskom modelu je neograničen. Pronalazak optimalnog (ili gotovo optimalnog) rješenja osigurano je implementiranim optimizacijskim alatom, genetskim algoritmom. Kako bi se pronašla optimalna rješenja pokreće se petlja koja definirana ulaznim parametrima genetskog algoritma: veličina populacije, broj generacija, broj opservacija. U poglavlju 3.2., objašnjen je utjecaj veličine populacije i broja generacija na konačna rješenja.

Princip rada simulacijskog okvira ukratko se može opisati na sljedeći način. Genetski algoritam određuje vrijednosti varijabli odlučivanja te izvodi simulacijske eksperimente za definirane varijable odlučivanja. Svakim simulacijskim eksperimentom generira se rješenje. Pritom, genetski algoritam teži pronalasku što boljeg rješenja (teži pronalasku minimalne ili maksimalne vrijednosti funkcije cilja). Postupak se ponavlja sve dok se ne zadovolji postavljeni uvjet zaustavljanja. Završetkom optimizacije dobivena su optimalna rješenja za varijable odlučivanja koja se unose u simulacijski model. Ponovno se izvodi simulacijski eksperiment, za dobivena optimalna rješenja varijabli odlučivanja, koji za rezultat daje optimalne vrijednosti za postavljene ciljeve. U ovom istraživanju potrebno je odrediti optimalno vremensko iskorištenje VLPS-a za slučajeve:

- najranijeg završetka proizvodnje,
- minimalnih vrijednosti srednjeg ciklusa izrade i ukupnog pripremno-završnog vremena uz osnovni uvjet isporuke na vrijeme,
- minimalnih troškova proizvodnje uz uvjet pravovremene isporuke.


5.3. Simulacijski model

Kako bi se stvorila podloga za razvoj simulacijskog okvira za početak je potrebno izraditi simulacijski model. Za potrebe ovog istraživanja izrađen je simulacijski model prema karakteristikama VLPS-a po uzoru na proizvodni sustav iz realnog okruženja. Prilikom modeliranja potrebno je pridržavati se određenih ograničenja karakterističnih za višepredmetne linijske proizvodne sustave, a to su:

- srednje ili velike količine većeg asortimana proizvoda jednosmjerno se kreću kroz proizvodni proces,
- u proizvodnom procesu postoji više od jedne faze u kojima se na jediničnim serijama proizvoda izvršava određena aktivnost (operacija),
- unutar svake faze proizvodnje može se nalaziti jedan ili više istovrsnih proizvodnih kapaciteta (strojeva),
- sve jedinične serije proizvoda podliježu prioritetima koji ih ograničavaju na jednak redoslijed izrade kroz sve faze proizvodnje,
- na svakom proizvodnom kapacitetu može se izvršavati najviše jedna aktivnost bilo koje jedinične serije proizvoda u istom vremenskom trenutku,

- ne smije se prekidati aktivnost koja je započela na nekom proizvodnom kapacitetu,
- određena aktivnost neke jedinične serije proizvoda može se izvršavati na samo jednoj vrsti proizvodnih kapaciteta, odnosno nema alternativnih usmjeravanja,
- ne postoji ograničenje duljine čekanja na izradu ili transport.

Ukupne proizvodne količine su podijeljene u manje cjeline, jedinične serije proizvoda. Prema definiranom redoslijedu, serije proizvoda ulaze u proizvodni sustav u određenom vremenskom trenutku. Način na koji se određuje koliko jedinica određenog proizvoda će sadržavati pojedina jedinična serija proizvoda, kao i način određivanja ulaska određene jedinične serije proizvoda, pojašnjeno je u sljedećem poglavlju. Korišteni programski paket je Tecnomatix Plant Simulation. Primjer simulacijskog modela dan je slikom 5.3.



Slika 5.3. *Primjer izrađenog simulacijskog modela VLPS-a*

Prilikom dolaska na neku od radnih stanica (faza), jedinična serija proizvoda se raspakirava na zajedničkom međuskladištu zaduženom za usmjeravanje proizvoda prema proizvodnim kapacitetima (strojevima). Korištenjem FCFS logike definiran je slijed odvijanja aktivnosti na pojedinom radnom mjestu. Drugim riječima, nakon što se oslobodi mjesto na nekom proizvodnom kapacitetu, prva jedinica proizvoda iz određene jedinične serije proizvoda koja čeka na izradu bit će i poslužena, odnosno na njoj će se izvršiti definirana aktivnost.

Završetkom aktivnosti, jedinica proizvoda se odlaže u izlazno međuskladište u kojem čeka preostale jedinice proizvoda iz iste jedinične serije da se na njima izvrši aktivnost. Kada je na

svim jedinicama proizvoda iz iste jedinične serije izvršena aktivnost tada je ta jedinična serija proizvoda spremna za transport na sljedeću radnu stanicu.

Dolaskom drugačije jedinične serije proizvoda na izradu, javlja se potreba za pripremno-raspripremom radnog mjesta, ograničenje 5.1. Pripremno-završno vrijeme se određuje prema uniformnoj razdiobi. U tom vremenu se obavljaju sve potrebne aktivnosti za nesmetano odvijanje operacija uključujući postavljanje odgovarajućih alata. Oštrica svakog alata ima svoju trajnost. Ukoliko oštrica alata obradi maksimalnu količinu proizvoda prije svog zatupljenja, pojavljuje se potreba za zamjenom alata, što predstavlja dodatno ograničenje 5.2. Vrijeme zamjene alata manje je od pripremno-završnog vremena. Također se određuje prema uniformnoj razdiobi.

$$pz_m > 0 \quad \forall \quad b_j \neq b_{j-1} \quad (5.1)$$

$$za_a > 0 \quad \forall \quad ba_a = ba_{max} \quad (5.2)$$

Ne treba zaboraviti da svaki stroj može stati s radom zbog kvara. Vjerojatnost pojave kvara procijenjena je prema podacima dobivenim od strane proizvodnog poduzeća iz realnog okruženja i definira se kao stopa pojave kvara. Prema istom principu se definira i stopa pojave škarta. Sve navedene aktivnosti utječu na vrijeme koje jedinična serija proizvoda provede u određenoj fazi proizvodnje. Drugim riječima, povećavaju vrijeme čekanja.

Nakon što se izrade sve jedinice proizvoda iz pojedine jedinične serije, na izlaznom međusklađištu ta jedinična serija proizvoda se transportira prema sljedećoj fazi proizvodnje. Prijenos jediničnih serija proizvoda između radnih stanica osiguran je transportnim sredstvom. Ovisno o masi tereta koji se prenosi, određuje se koje transportno sredstvo se koristi za promatrani sustav. Detaljnije objašnjeno u poglavlju 4.1.2. Ukoliko je transportno sredstvo zauzeto u nekom vremenskom trenutku, pojedina jedinična serija proizvoda mora čekati na transport, a to znači da je prijenos jediničnih serija proizvoda između faza u proizvodnji uvjetovan dostupnošću transportnog sredstva. Može se dogoditi da više pojedinih jediničnih serija proizvoda u istom vremenskom trenutku čeka na transport. Nakon što transportno sredstvo otpusti prethodni teret ono odabire onu jediničnu seriju proizvoda koja najduže čeka na transport, prema FCFS pravilu.

Završenim premještanjem određena jedinična serija proizvoda dolazi u ulazno međusklađište sljedeće faze u kojem čeka na obavljanje predviđenih aktivnosti u toj fazi. Izvršenjem svih

operacija, odnosno svih predviđenih aktivnosti za određenu vrstu proizvoda, jedinična serija tog proizvoda se transportira u skladište gotovih proizvoda u kojem čeka na isporuku.

5.4. Određivanje veličine jediničnih serija i redoslijeda ulaska jediničnih serija u sustav

Ranije je navedeno kako su jedni od najvažnijih zadataka planiranja proizvodnje, određivanje redoslijeda i veličine jediničnih serija. Stoga, u ovom radu redoslijed ulaska jediničnih serija proizvoda i veličine jediničnih serija proizvoda promatraju se kao varijable odlučivanja. S ciljem osiguranja jednostavnijeg upravljanja i vođenja proizvodnje što je nerijetko i zahtjev proizvodnih poduzeća iz realnog okruženja, u ovom radu se veličina jediničnih serija promatra kao fiksna vrijednost za određenu vrstu proizvoda.

Veličina jedinične serije predstavlja dio ukupne količine proizvoda, određene radnim nalogom, koja ulazi u proizvodni proces u određenom vremenskom trenutku i prolazi kroz proizvodni proces kao jedna cjelina, u poglavlju 2.1.2. detaljnije pojašnjeno. Prema tome, veličina jedinične serije može se na jednostavan način prikazati kao brojčana vrijednost. Veličinu jedinične serije j -tog proizvoda Lot_j definira se kao prirodni broj u određenom intervalu, prema izrazu 5.3. Pri čemu je Lot_{min} minimalna veličina jedinične serije (donja granica), a Lot_{max} maksimalna veličina jedinične serije j -tog proizvoda (gornja granica). Postoje dva ograničenja na koje vrijedi obratiti pozornost prilikom određivanja veličine jediničnih serija. Prvo je da vrijednost minimalne veličine jedinične serije mora biti definirana većom od jedan, ograničenje 5.4. Ukoliko je veličina jedinične serije jednaka jedan onda se radi o besprekidnoj proizvodnji, odnosno tada proizvodi ne prolaze kroz sustav kao određena cjelina nego se promatraju kao zasebne jedinice. Drugo ograničenje 5.5., je da maksimalna veličina jedinične serije ne može biti veća od ukupne količine proizvoda q_j .

$$Lot_j \in [Lot_{min}, Lot_{max}], \quad \forall Lot_j \in \mathbb{N} \quad (5.3)$$

$$Lot_{min} > 1 \quad (5.4)$$

$$Lot_{max} < q_j \quad (5.5)$$

Uzimajući bilo koji broj iz definiranog intervala (raspona) kao veličinu jedinične serija omogućuje se puno više potencijalnih rješenja u odnosu na mnoge autore. Primjerice, Brajković

i sur. (2018.) koriste različite veličine jedinične serije proizvoda s pretpostavkom da ukupna količina proizvoda mora biti višekratnik veličine jedinične serije proizvoda (ukupna količina proizvoda mora biti dijeljiva s veličinom jedinične serije), što uvelike smanjuje mogućnosti pronalaska kvalitetnijeg rješenja.

Ako se pretpostavi da je svaka jedinična serija istog proizvoda jednaka, neovisno o ukupnoj proizvodnoj količini proizvoda, vrlo je vjerojatno da se neće proizvesti potrebna količina proizvoda. Proizvest će se ili premalo ili previše jedinica proizvoda.

Jednostavan primjer: Dvotjedna količina proizvoda koju treba proizvesti je 1234 jedinica proizvoda. Veličina jedinične serije je 400 jedinica proizvoda. Vidljivo je da ako se proizvedu tri jedinične serije od 400 jedinica proizvoda da nedostaje još 34 jedinice proizvoda za proizvesti, a to se svakako želi izbjeći. Ukoliko se proizvedu četiri jedinične serije od 400 jedinica proizvoda na zalihi će biti 366 jedinica proizvoda, što će povećati samo odvijanje proizvodnje, a samim time će povećati mogućnost ne zadovoljavanja isporuke na vrijeme. Time se stvara i zaliha na skladištu koja stvara dodatni trošak. Iz tog razloga osigurava se da posljednja jedinična serija istog proizvoda bude jednaka kao:

$$Lot_{j,ost} = q_j - (b_j - 1) \cdot Lot_j \quad (5.6)$$

gdje je: $Lot_{j,ost}$ - veličina posljednje jedinične serije j -tog proizvoda,
 $Lot_{j,ost} \in [Lot_{min}, lot_{max}]$

q_j - ukupna proizvodna količina j -tog proizvoda

b_j - broj jediničnih serija j -tog proizvoda

Lot_j - veličina jedinične serije j -tog proizvoda

Na taj način osigurava se jednostavnije upravljanje i vođenje proizvodnje jer su sve jedinične serije određenog proizvoda i dalje jednake, osim posljednje jedinične serije koja je modificirana kako bi se zadovoljila količina proizvoda koju je potrebno proizvesti. Broj jediničnih serija proizvoda j određuje se kako slijedi:

$$b_j = \frac{q_j}{Lot_j} \quad (5.7)$$

Dobivena vrijednost se zaokružuje na prvi veći cijeli broj.


Dok je veličinu jedinične serije jednostavno prikazati kao brojčanu vrijednost, to nije slučaj za redoslijed ulaska jediničnih serija. Za određivanje redoslijeda ulaska određene jedinične serije u ovom radu se koristi vjerojatnost ulaska jediničnih serija. Zapravo, jediničnoj seriji j -tog proizvoda dodjeljuje se težinska vrijednost Red_j iz određenog intervala, definirana kao prirodni broj prema izrazu:

$$Red_j \in [dg, gg], \quad \forall Red_j \in \mathbb{N} \quad (5.8)$$

Pritom, dg predstavlja donju granicu, a gg gornju granicu težinske vrijednosti koju jedinična serija j -tog proizvoda može poprimiti. Na temelju određenih težinskih vrijednosti probabilističkom metodom se odabire jedinična serija j -tog proizvoda koja će ući u proces, te na taj način određuje redoslijed ulaska jediničnih serija proizvoda.

5.5. GA optimizacija

Prije pokretanja genetskog algoritma određuju se ulazni parametri GA (slika 5.4.):



Slika 5.4. GA parametri optimizacije

Veličinom populacije se određuje koliki će biti broj jedinki (kromosoma) u jednoj populaciji. Samim time veličinom populacije se određuje veličina prostora pretrage za pronalazak optimalnog (ili gotovo optimalnog) rješenja za predloženi problem. Broj generacija ujedno predstavlja broj ponavljanja sljedećih populacija. S obzirom na problem istraživanja, nije poznato kojem rješenju se teži, tj. ne zna se kako izgleda optimalno rješenje. Iz tog razloga, broj generacija potrebno je definirati nekim konačnim brojem, pazeći da broj generacija bude dovoljan za pronalazak optimalnog (ili gotovo optimalnog rješenja) a da s druge strane ne bude prevelik kako sami postupak ne bi bio dugotrajan. Brojem opservacija se uvjetuje koliko će biti ponavljanja eksperimenata koristeći iste ulazne podatke.

5.5.1. Predstavljanje jedinki

U fazi inicijalizacije jedinke se nasumično generiraju u početnoj populaciji. Pritom se svakoj jedinki dodjeljuju određene karakteristike. Te karakteristike predstavljaju varijable odlučivanja. U ovom radu varijable odlučivanja koje se koriste za optimiranje nekih mjera uspješnosti su vjerojatnost ulaska jedinične serije i veličina jedinične serije određenog proizvoda. Svaka jedinka može se prikazati kao kromosom, prema slici 5.5., tj. kao niz gena gdje je Lot_j gen za veličinu jedinične serije j -tog proizvoda odnosno Red_j predstavlja gen za vjerojatnost ulaska jedinične serije. Ovdje je bitno naglasiti da broj gena ovisi o broju različitih vrsta proizvoda.

Lot_1	..	Lot_j	..	Lot_n	Red_1	..	Red_j	..	Red_n
---------	----	---------	----	---------	---------	----	---------	----	---------


Slika 5.5. Umjetni kromosom za veličinu jedinične serije i vjerojatnost ulaska jedinične serije za svaku vrstu proizvoda

Svaka jedinka se zatim procjenjuje u fazi evaluacije na način da se za određene vrijednosti varijabli odlučivanja, koje opisuju pojedinu jedinku iz populacije, izvodi simulacijski eksperiment. Kao rezultat simulacijskih eksperimenata dobiju se rješenja prema definiranoj funkciji cilja za svaku jedinku iz populacije.

5.5.2. Odabir jedinki za reprodukciju

Na osnovi dobivenih rješenja stohastičkom metodom se odabiru jedinke za reprodukciju. Stohastička metoda koja se koristi pri odabiru jedinki za reprodukciju je jednostavna proporcionalna selekcija. Poznatija pod nazivom odabir kotačem ruleta (engl. *Roulette wheel*


selection) predstavlja selekcijski proces kod koje je vjerojatnost odabira jedinke proporcionalna vrijednosti rješenja jedinke (slika 5.6.). Najveću vjerojatnost odabira ima ona jedinka s najboljim rješenjem funkcije cilja. Suprotno, najmanju vjerojatnost odabira ima ona jedinka koja ima najlošiju vrijednost rješenja. Ovim postupkom selekcije jedna jedinka može biti odabrana nekoliko puta za reprodukciju, ali isto tako ne mora biti odabrana niti jednom.



Slika 5.6. Stohastička metoda odabira - odabir kotačem ruleta (Newcastle University, 2021.)

5.5.3. Križanje u dvije točke i mutacija dodjelom

Jedinke odabrane za reprodukciju predstavljaju roditelje, kao oca i majku. Reprodukciom nastaju potomci koji posjeduju iste karakteristike kao i roditelji. Na potomke se zatim primjenjuju genetski operatori. Ovisno o vjerojatnosti pojave genetskih operatora ovisi hoće li se genetski operatori primijeniti na potomke. Prema tome, postoji mogućnost da potomci kao preslika svojih roditelja budu izabrani u sljedeću generaciju. Prvi genetski operator koji se primjenjuje je operator križanja u dvije točke. Primjenjuje se tako da prvi potomak naslijedi dio gena od oca, a drugi dio od majke, vidi sliku 5.7. Dok drugi potomak nasljeđuje preostale gene. Drugi genetski operator koji se primjenjuje na svakog potomka zasebno je operator mutacije dodjelom. Operator mutacije dodjelom primjenjuje se prema izrazima 5.3. i 5.8., tako da se određenom genu dodjeljuje nova vrijednost iz definiranog skupa (slika 5.8.). Promjena vrijednosti (mutacija) određenog gena ovisi o vjerojatnosti pojave operatora mutacije.




Slika 5.7. Križanje u dvije točke - zamjenjuju se geni između pozicija 3 i 5



Slika 5.8. a) prvi potomak - mutacija na drugom i petom genu; b) drugi potomak - bez mutacije


Ne postoji optimalna vrijednost koja se određuje za vjerojatnost pojave genetskih operatora. Određuje se prema problemu rješavanja isprobavanjem različitih kombinacija genetskih operatora. Vrijednosti genetskih operatora u programskom paketu Tecnomatix Plant Simulation definiraju kako je prikazano na slici 5.9.



Slika 5.9. Odabir vrijednosti parametara genetskih operatora

5.5.4. Probabilistička selekcija nove populacije

Prethodno navedenim postupcima stvorene su nove jedinke, novi članovi populacije (potomci). Za svaku novonastalu jedinku izvodi se simulacijski eksperiment s ciljem dobivanja rješenja prema definiranoj funkciji cilja. Kako bi se onemogućio gubitak najboljeg rješenja, postavljeno je da se ono automatski prenosi u sljedeću populaciju. Takav mehanizam se naziva elitizam. Između preostalih jedinki, roditelja i potomstva, probabilističkom metodom se odabiru jedinke koje će preživjeti, tj. koje će se koristiti u sljedećoj generaciji. Kako definirati parametre selekcije u programskom paketu Tecnomatix Plant Simulation, prikazano je slikom 5.10.



Slika 5.10. Selekcija jedinki za reprodukciju i odabir jedinki za novu populaciju

5.5.5. Uvjet zaustavljanja

Probabilističkom selekcijom stvorena je nova populacija od istog broja jedinki kao i prethodna generacija. Genetski algoritam ponavlja prethodno navedene postupke dok ne dostigne uvjet zaustavljanja. U ovom radu uvjet zaustavljanja definiran je postavljenim brojem generacija.

5.6. Simulacijski eksperiment

Završetak optimizacije rezultirat će optimalnim (ili gotovo optimalnim) rješenjima za promatrani slučaj. Drugim riječima, genetskim algoritmom će se dobiti najbolja rješenja za

određenu funkciju cilja. Rezultat optimizacije su dobivene optimalne vrijednosti varijabli odlučivanja, vjerojatnosti ulaska jediničnih serija i veličine jediničnih serija.

Dobivene optimalne vrijednosti vjerojatnosti ulaska jediničnih serija i veličine jediničnih serija se unose u simulacijski model te se pokreće simulacijski eksperiment koji će za rezultat dati redoslijed ulazaka jediničnih serija j -tih proizvoda te dati uvid u rješenja za traženu funkciju cilja, tj. tražene mjere uspješnosti.

Redoslijed se prikazuje na jasan i jezgrovit način u vidu Ganttovih dijagrama. Ganttovim dijagramom ili gantogramom je dan detaljan prikaz vremenskih trenutaka kada pojedina jedinična serija j -tog proizvoda ulazi u proizvodni sustav, kada se dodjeljuje određenom proizvodnom resursu te također, daje vremenski trenutak kada izlazi iz proizvodnog sustava, slanjem u skladište gotovih proizvoda. Samim tim, određeno je vremensko iskorištenje promatranog sustava, odnosno poznato je koliko vremena je potrebno kako bi se proizvele definirane količine j -tih proizvoda. Vremensko iskorištenje VLPS-a se razlikuje s obzirom na postavljenje ciljeve koji se teže ostvariti.

Poglavlje 6: STUDIJA SLUČAJA I REZULTATI EKSPERIMENTALNIH ISTRAŽIVANJA

U realnom okruženju, proizvođač od kupca primi narudžbu izrade nekog proizvoda (ili više njih) u određenoj količini. Prilikom planiranja operativne pripreme proizvodnje određuje se koliko će se određene vrste proizvoda proizvesti u promatranom razdoblju ovisno o terminima isporuke definiranim od strane naručitelja.

Studija slučaja je primjenjena na konkretnom primjeru proizvodnog poduzeća ABC koje se bavi proizvodnjom tehnološki složenih proizvoda. Trenutnu proizvodnju bilo je potrebno učiniti jednostavnijom i učinkovitijom tako da se grupiraju tri tehnološki slična proizvoda u jedan proizvodni proces s osnovnim ciljem isporučivanja ugovorenih količina proizvoda D, proizvoda E i proizvoda F na vrijeme.

Nakon obrade i kontrole proizvodi se pakiraju i isporučuju naručitelju. Isporuca ugovorenih količina predviđena je svakih dva tjedna. Tablicom 6.1. prikazane su ugovorene količine navedenih proizvoda kao i preporučene veličine jediničnih serija. Proizvodnja se odvija tijekom pet radnih dana u tjednu (od ponedjeljka do petka) u dvije radne smjene. Svaka radna smjena traje osam sati. Prema izrazu 4.2, izračunava se maksimalno raspoloživo vrijeme za obradu navedenih proizvoda $C_{max,goal} = 80$ sati. Vrijeme potrebno za izradu proizvoda D, E, F u promatranom poduzeću je približno jednako maksimalno raspoloživom vremenu $C_{max,goal}$. To

znači da ukoliko dođe do nepredviđenih zastoja isporuka će kasniti, a to se želi izbjeći. Stoga je potrebno odrediti redoslijed i veličinu jediničnih serija kako bi se smanjilo potrebno vrijeme za proizvodnju navedenih proizvoda.

Tablica 6.1. Ulazni podaci - proizvodni program

Proizvod j	Ukupna količina proizvoda q_j [kom]	Veličina jedinične serije Lot_j [kom]
Proizvod D	680	30
Proizvod E	840	30
Proizvod F	560	30

Proizvodni sustav sastoji se od pet faza u procesu u kojima se nalaze redom 2, 3, 3, 1 i 2 stroja. Svi strojevi u pojedinoj fazi proizvodnje su istog tipa. Tablicom 6.2. dani su redoslijed i vrijeme odvijanja operacija. Pritom, redni broj operacije jednak je rednom broju faze proizvodnje u kojoj se operacija izvršava dok su vremena prikazana u formatu minute:sekunde.

Tablica 6.2. Ulazni podaci - redoslijed i vrijeme odvijanja operacija

Operacija	Vrijeme operacije [min]			Broj strojeva u fazi
	Proizvod D	Proizvod E	Proizvod F	
1	5:30	3:30	5:00	2
2	8:30	11:00	8:00	3
3	12:30	8:30	10:00	3
4	3:00	3:00	3:30	1
5	6:30	8:00	5:30	2

Osim vremenom operacije, izvedba pojedinog stroja uvjetovana je i drugih parametrima: vremenom potrebnim za pripremu i raspremu uslijed dolaska različite vrste proizvoda u odnosu na prethodnu, kao i raspoloživosti stroja i prosječnim vremenom za popravak (engl. *Mean Time To Repair*, MTTR) te stopom pojave škarta, tablica 6.3. Istom tablicom su također dane vrijednosti za broj strojeva unutar svake faze proizvodnje te njihova amortizacijska vrijednost.

Definirane vrijednosti su jednake za sve strojeve unutar jedne faze proizvodnje, jer se radi o identičnim strojevima. Pripremno-završno vrijeme je definirano kao uniformna razdioba.

Tablica 6.3. Ulazni podaci - Proizvodni kapaciteti

	Broj strojeva	t_{pZ} [min]	p_m [%]	$MTTR$ [min]	p_s [%]	AV_m [n.j./danu]
Faza 1	2	U[5,15]	98	10	2	100
Faza 2	3	U[20,45]	97	15	3	1050
Faza 3	3	U[20,35]	98	15	2	1450
Faza 4	1	U[10,30]	95	10	5	200
Faza 5	2	U[10,20]	95	10	5	240

Na izvedbu pojedinog stroja također utječe i potreba za zamjenom istrošenih alata. Potreba za zamjenom alata ovisi o veličini jedinične serije i maksimalnom broju jedinica proizvoda koji alat može izraditi prije istrošenja. Cijena svakog alata, kao i količina proizvoda koju je moguće izraditi prije istrošenja oštice te prosječno vrijeme zamjene alata, prikazani su u tablici 6.4. Vrijeme zamjene alata definirano je uniformnom razdiobom. Zbog pojednostavljenja, na strojevima unutar prve, četvrte i pete faze proizvodnje koristi se samo jedna vrsta alata dok se unutar druge i treće faze proizvodnje koriste tri vrste alata te se na tim strojevima primjenjuje zamjena alata. Vrijedi napomenuti da se za izradu proizvoda D koriste alati $T1$ i $T2$, za izradu proizvoda E alati $T1$ i $T3$, dok za izradu proizvoda F koristi se alat $T2$. Cijena alata koji se koristi na preostale tri radne stanice je redom: 300 n.j., 1800 n.j. i 1000 n.j. (novčanih jedinica).

Tablica 6.4. Ulazni podaci - Alati

	T_a [n.j.]	ba_{max} [kom]	za_a [min]
Alat $T1$	375	30	U(3,5)
Alat $T2$	575	30	U(2,4)
Alat $T3$	270	25	U(3,4)

Prijenos jediničnih serija proizvoda osiguran je korištenjem jedne od tri varijante transportnog sredstva. Tablicom 6.5. su prikazane varijante transportnih sredstava s pripadajućim brzinama

kretanja i amortizacijskom vrijednošću. Trošak radnika kao transportnog sredstva prikazuje se kao amortizacijska vrijednost, a ogleda se kroz prosječnu brutto plaću procijenjenu po danu. Proizvodnja se odvija u dvije smjene, prema tome potrebna su dva radnika za jedan radni dan, odnosno trošak radnika računa se kao dvije brutto plaće radnika. Nadalje, vrijedi napomenuti kako se trošak viličara kao transportnog sredstva sastoji od dva dijela, amortizacijske vrijednosti viličara i troška brutto plaće radnika po danu. Udaljenost između pojedinih faza u procesu je sljedeća: između prve i druge te četvrte i pete je 12 metara, dok je između preostalih faza udaljenost 8 metara.

Tablica 6.5. Ulazni podaci - Transport

	v_l [m/s]	AV_l [n.j./danu]
Radnik	1.5	1600
Pokretna traka	1	115
Viličar	1	185

Tablica 6.6. prikazuje cijenu ulaznog materijala za zadane proizvode. Također, prikazuje cijenu skladištenja poluproizvoda i gotovih proizvoda. Cijena repromaterijala se odnosi na jedinicu proizvoda, dok se cijena skladištenja odnosi na trošak skladištenja jedinice proizvoda za jedan dan.

Tablica 6.6. Ulazni podaci - Proizvodi

	$T_{rpm,j}$ [n.j.]	$T_{srm,j}$ [n.j./danu]	$T_{sgp,j}$ [n.j./danu]
Proizvod D	9.92	2.5	20
Proizvod E	5.68	2.5	12.5
Proizvod F	6.51	2.5	20

S obzirom da se razmatra isključivo problem planiranja proizvodnje, ostali podsustavi koji utječu na proizvodnju, ali sami nisu dio proizvodnje (nabava, prodaja) se zanemaruju. Stoga, pretpostavlja se kako stalno postoji dovoljna količina ulaznog materijala (sirovine) potrebnog za proizvodnju navedenih vrsta proizvoda kao i da će se svi proizvedeni proizvodi isporučiti.

6.1. Izrada simulacijskog modela VLPS-a


Svaka simulacija diskretnih događaja u sebi sadrži simulacijski sat, pa tako i programski paket Tecnomatix Plant Simulation koji je korišten za potrebe ovog istraživanja. Simulacijski sat se definira objektom *EventController*. Zadaća simulacijskog sata je koordiniranje i sinkroniziranje različitih događaja koji se odvijaju tijekom simulacije. Plant Simulation je sustav simulacije diskretnih događaja koji prikazuje promjene stanja komponenti modela u određenim vremenskim razdobljima, a ne kontinuirano tijekom vremena (Bangsow, 2020).

Kada proizvod ulazi u stanicu za obradu, npr. stroj, Plant Simulation izračunava vrijeme potrebno za izradu te unosi taj događaj i to vrijeme u popis planiranih događaja *EventController*-a. Plant Simulation te događaje razmatra na diskretan način, korak po korak. Glavna prednost ovog pristupa je da preskače vrijeme koje protekne u stvarnom vremenu između događaja. *EventController* se kreće duž vremenske linije poput reproduksijske glave video rekordera i interpretira poruke koje se odnose na događaje koje objekti izvršavaju. Nakon proteka vremena obrade, *EventController* prelazi na objekt koji mora pokrenuti izlazni događaj. Proizvod zatim prelazi na objekt koji slijedi. Tamo opet, Plant Simulation izračunava vrijeme izlaza i prosljeđuje ga *EventController*-u. Zatim postavlja marker u trenutku kada objekt mora premjestiti proizvod na sljedeći objekt. Plant Simulation ponavlja ovaj proces ciklički za sve proizvode koji se nalaze u simulacijskom modelu.


Korištenjem programskog paketa Tecnomatix Plant Simulation izrađen je simulacijski model VLPS-a prema podacima dobivenim od strane proizvodnog poduzeća ABC. Simulacijski model i pojedine faze prikazani su slikama 6.1.-6.6. Ulaz svih proizvoda u sustav definiran je objektom *Source* koji predstavlja skladište repromaterijala. Tim objektom se generiraju jedinične serije proizvoda prema određenom rasporedu.

S druge strane, izlaz svih proizvoda iz sustava definiran je postavljenim objektom *Drain* koji predstavlja skladište gotovih proizvoda. Objekt *Stage* služi za grupiranje objekata i za izgradnju hijerarhijski strukturiranih modela umetanjem bilo kojeg objekta. Predstavlja radni okvir, ali i oblikovane radne podokvire. U ovom istraživanju, radni okvir prikazuje cijeli proizvodni pogon, a radni podokviri prikazuju faze u proizvodnji (radne stanice).


Pomoću objekta *Interface* povezuju se proizvodni pogon i faze u proizvodnji (radni okvir i podokvir).




Slika 6.1. Simulacijski model VLPS-a izrađen u programskom paketu Tecnomatix Plant Simulation




Slika 6.2. Simulacijski model VLPS-a - prva faza proizvodnje




Slika 6.3. Simulacijski model VLPS-a - druga faza proizvodnje



Slika 6.4. Simulacijski model VLPS-a - treća faza proizvodnje




Slika 6.5. Simulacijski model VLPS-a - četvrta faza proizvodnje




Slika 6.6. Simulacijski model VLPS-a - peta faza proizvodnje

U svakoj fazi proizvodnje (*Stage*) je postavljen definiran broj strojeva u obliku objekata *Machine*. Otvaranjem dijaloškog okvira *Machine* unutar kartice *Failure* se postavlja raspoloživost proizvodnog kapaciteta i vrijeme za popravak prema tablici 6.3. Unutar kartice *Times* unosi se vrijeme pripreme i raspreme za taj stroj, slika 6.7.




Slika 6.7. Dijaloški okvir *Machine* - uneseni raspon pripremno-završnog vremena

Ovisnost pripremno-završnog vremena o slijedu proizvoda, definira se u kartici *Set-up*. U kartici *Controls* dodaju metode *self.OnEntrance* (slika 6.8.) koja se poziva svaki puta kada bilo koji proizvod dođe do stroja i *self.OnSetup* (slika 6.9.) koja se poziva prilikom dolaska različite serije proizvoda. Metoda *self.OnEntrance*, između ostalog, postavlja vrijeme operacije za pojedini proizvod preuzimajući podatke iz tablice *ProcTime*, na način da prvo prepozna o kojem se proizvodu radi te na temelju toga dodijeli vrijeme potrebno za izradu. Taj postupak je napravljen na svakom objektu *Machine*. U tablici *ProcTime* se nalaze vremena operacija za definirane proizvode prema tablici 6.2. Tablica *ProcTime* se sastoji od tri podtablice, slika 6.10. Svaka podtablica daje vremena operacija za pojedini proizvod (D, E i F). Vremena su izražena u formatu minute:sekunde [min:sec]. Na kraju, u kartici *Energy* unose se vrijednosti potrošnje električne energije za vrijeme rada stroja i rada u stanju mirovanja.



Slika 6.8. Metoda OnEntrance - služi za postavljanje vremena operacija te uvjetuje zamjenu alata uslijed istrošenja oštice



Slika 6.9. Metoda OnSetup - služi za izračun ukupnog pripremno-završnog vremena

	string 0	table 1
string	Proizvod	Tablica vremena operacija
1	PartD	x
2	PartE	x
3	PartF	x

	string 0	time 1
string	Operacija	Vrijeme
1	1	5:30.0000
2	2	8:30.0000
3	3	12:30.0000
4	4	3:00.0000
5	5	6:30.0000

	string 0	time 1
string	Operacija	Vrijeme
1	1	3:30.0000
2	2	11:00.0000
3	3	8:30.0000
4	4	3:00.0000
5	5	8:00.0000

	string 0	time 1
string	Operacija	Vrijeme
1	1	5:00.0000
2	2	8:00.0000
3	3	10:00.0000
4	4	3:30.0000
5	5	5:30.0000

Slika 6.10. Tablica ProcTime - redoslijed i vremena operacija za proizvode D, E i F

Jedinica proizvoda u simulacijskom modelu prikazana je objektom *Part*. Jedinice proizvoda kreću se kroz proces kao cjelina pomoću određenog spremnika. Spremnik može predstavljati paletu, kontejner ili kutiju, a definira se objektom *Container*. Pri dolasku na ulazno međuskladište jedinice proizvoda se raspakiravaju, a zatim svaka jedinica proizvoda čeka na izradu. Za to vrijeme spremnik (paleta) odlazi na mjesto izlaznog međuskladišta gdje čeka da sve jedinice proizvoda iz te jedinične serije završe s izradom u toj fazi proizvodnje. Završetkom izrade u toj fazi proizvodnje pojedina jedinica proizvoda popunjava spremnik na mjestu izlaznog međuskladišta. Međuskladišni prostori predstavljaju svojevrsan oblik radnog stola na koji se odlažu proizvodi. Definira se pomoću objekta *Buffer*. Objektom *FlowControl* postavlja se pravilo FCFS, odnosno da će prvi proizvod iz reda čekanja prvi biti i poslužen.

Prijenos jediničnih serija proizvoda (spremnika), između faza u procesu izvršava se korištenjem određenog transportnog sredstva. Koja vrsta transportnog sredstva se koristi ovisi o masi tereta koji se prenosi (detaljnije objašnjeno u poglavlju 4.1.2.). Predložene tri varijante transportnog sredstva s procjenjenim brzinama kretanja prikazuju se na sljedeći način:

- radnik (1.5 m/s) - objekt *Worker*
- pokretna traka (1 m/s) - objekt *Conveyor*
- viličar (1 m/s) - objekt *Transporter*

Također, postavlja se i objekt *ShiftCalendar* koji predstavlja kalendar radnog tjedna. Ovim objektom definiraju se radni dani i radne smjene, prema slici 6.11. Kraj smjene, odnosno u ovom slučaju završetak druge smjene, pauzira aktivnosti u simulacijskom modelu. Strojevi se ponovno pokreću kada započne nova radna smjena. Time se dobiva realno stanje s točnim vremenima kada se nešto odvija. Metoda *Init* aktivira se pokretanjem simulacije. Tom metodom je dodjeljuju određene početne vrijednosti za ulazne podatke. Za razliku od metode *Init*, metoda *EndSim* se aktivira završetkom simulacije. Služi za izračunavanje izlaznih podataka, prema izrazima iz poglavlja 4. Funkcija cilja je definirana unutar metode *FitnessMethod*, detaljnije objašnjeno u poglavlju 6.3. Kako bi se dobiveni podaci sveli na početne vrijednosti pri pokretanju novog simulacijskog eksperimenta osigurano je pomoću metode *Reset*.

Shift	From	To	Mo	Tu	We	Th	Fr	Sa	So	Pauses
1 Shift-1	6:00	14:00	☒	☒	☒	☒	☒	☐	☐	
2 Shift-2	14:00	22:00	☒	☒	☒	☒	☒	☐	☐	

Slika 6.11. Kalendar radnih smjena

Na kraju, korištenjem objekta *Variable* definiraju se mnoge varijable čija se vrijednost računa izvođenjem simulacijskog eksperimenta. Najvažnije definirane varijable su:

- Varijable odlučivanja:
 - *LotSizeD* - veličina jedinične serije proizvoda D
 - *LotSizeE* - veličina jedinične serije proizvoda E
 - *LotSizeF* - veličina jedinične serije proizvoda F

- *RedD* - vjerojatnost ulaska jedinične serije proizvoda D
- *RedE* - vjerojatnost ulaska jedinične serije proizvoda E
- *RedF* - vjerojatnost ulaska jedinične serije proizvoda F
- Funkcija cilja:
 - *makespan* - vrijeme završetka proizvodnje (završetak simulacije)
 - *MeanFlowTimeD* - srednji ciklus izrade proizvoda D
 - *MeanFlowTimeE* - srednji ciklus izrade proizvoda E
 - *MeanFlowTimeF* - srednji ciklus izrade proizvoda F
 - *TotalSetupTimeD* - ukupno pripremno-završno vrijeme proizvoda D
 - *TotalSetupTimeE* - ukupno pripremno-završno vrijeme proizvoda E
 - *TotalSetupTimeF* - ukupno pripremno-završno vrijeme proizvoda F
 - *TotalCosts* - ukupni trošak proizvodnje
- Ulazni podaci:
 - *ProdVolD* - proizvodna količina proizvoda D
 - *ProdVolE* - proizvodna količina proizvoda E
 - *ProdVolF* - proizvodna količina proizvoda F
- Izlazni podaci:
 - *FinishedD* - količina proizvedenih proizvoda D
 - *FinishedE* - količina proizvedenih proizvoda E
 - *FinishedF* - količina proizvedenih proizvoda F
 - *LotNumD* - broj jediničnih serija proizvoda D
 - *LotNumE* - broj jediničnih serija proizvoda E
 - *LotNumF* - broj jediničnih serija proizvoda F


6.2. Verifikacija i validacija simulacijskog modela

Sljedeći korak koji je napravljen je verifikacija i validacija simulacijskog modela. Postupak verifikacije se izvodio konstantno tijekom izrade simulacijskog modela. Tim postupkom se provjeravala ispravnost unesenih podataka i rada simulacijskog modela te da li elementi modela u odgovarajućoj mjeri predstavljaju elemente iz stvarnog sustava. Kada je simulacijski model izrađen u potpunosti, onda se ispravnost odvijanja procesa unutar izrađenog simulacijskog modela provjeravala događaj po događaj (engl. *Step by Step*). Utvrđeno je da simulacijski model u odgovarajućoj mjeri opisuje stvarni sustav.

Nakon toga, bilo je potrebno provesti postupak validacije. Validacija se provjerava na način da se izvode simulacijski eksperimenti. Ukoliko se rezultati eksperimentiranja u velikoj mjeri podudaraju s rezultatima stvarnog sustava, tada se može tvrditi da je model validan. Stoga, provedena su dva testa. Prvi test je uključivao provjeru rezultata na temelju sljedećih podataka:

- proizvode se proizvodi D, E i F,
- obrađuje se jedna jedinična serija svakog proizvoda u količini od 12 jedinica proizvoda,
- vrijeme svake od pet operacija je 1 minuta (za svaki proizvod),
- raspoloživost strojeva postavljena je na 100 %,
- stopa pojave škarta postavljena je na nula,
- transportno sredstvo je pokretna traka,
- priprema i rasprega radnog mjesta te zamjena alata nije uključena.


Prema predloženim podacima, matematički je izračunato da vrijeme završetka proizvodnje iznosi 56 minuta i 40 sekundi. Pokrenutim simulacijskim eksperimentom dobiven je identičan rezultat, slika 6.12. Također, ispravnost rezultata se može vidjeti i po broju proizvedenih proizvoda *FinishedD* koji je jednak broju proizvodne količine *ProdVolD*. Isto vrijedi i za proizvode E i F.



Slika 6.12. Validacija simulacijskog modela - prva provjera

Drugi test je napravljen tako da su u simulacijski model uneseni svi ranije definirani podaci (Tablica 6.1.-6.6.) preuzeti od strane proizvodnog poduzeća ABC te je pokrenut simulacijski eksperiment. Dobiveni rezultat simulacijskog eksperimentiranja prikazan je slikom 6.13. Može se primijetiti da vrijeme završetka simulacije, odnosno završetka proizvodnje iznosi 6:16:20:34 [dani:sati:minute:sekunde]. Navedeni format koristit će se dalje kroz ovaj rad. Usporedbom

stvarnog raspoloživog vremena i vremena završetka proizvodnje u simulaciji primijećuje se neznatna razlika koja je uzrokovana pojavom različitih nesigurnosti i varijacija definiranih ulaznih parametara, poput pripremno-završnog vremena ili pojave škarta. Odstupanje iznosi 20 minuta i 34 sekunde ili 0.428 %. Prema tome, na temelju rezultata ove dvije provjere slobodno se može tvrditi da je izrađeni simulacijski model promatranog VLPS-a ispravno postavljen.



Slika 6.13. Validacija simulacijskog modela - druga provjera (prema podacima iz realnog okruženja)

6.3. Primjena simulacijskog okvira za studiju slučaja

Potvrđenom ispravnošću predloženog simulacijskog modela može se pristupiti optimizaciji. Za navedeni proizvodni proces potrebno je odrediti redoslijed ulaska jediničnih serija proizvoda u sustav i veličinu jediničnih serija proizvoda D, E i F kako bi se optimiralo vremensko iskorištenje predloženog VLPS-a.

Optimizacija je izvršena korištenjem optimizacijskom alata, genetskog algoritma koji je implementiran unutar razvijenog simulacijskog okvira. Provedena je za tri zasebna slučaja koji proizlaze iz hipoteze ovog rada, a to su:

- Slučaj 1. najraniji završetak proizvodnje
- Slučaj 2. minimiziranje vrijednosti srednjeg ciklusa izrade i ukupnog pripremno-završnog vremena uz osnovni uvjet pravovremene isporuke. Time će se dobiti optimalno vremensko iskorištenje VLPS-a.
- Slučaj 3. minimiziranje troškova proizvodnje uz osnovni uvjet isporuke na vrijeme, te na taj način određivanje optimalnog vremenskog iskorištenja VLPS-a.

Rezultati za pojedini slučaj dobiveni su tako da su isprobane različite vrijednosti parametara genetskog algoritma izvođenjem velikog broja eksperimenata. Na taj način stečeno iskustvo pokazalo je superiornost nekih, te su prikazani samo najbolji rezultati.

6.3.1. Slučaj 1 - najraniji završetak proizvodnje

Genetski algoritam je primjenjen kako je objašnjeno u poglavlju 5.5. Unesene su sljedeće vrijednosti za parametre genetskog algoritma:

- broj članova populacije, $vel_pop = 30$
- broj generacija, $br_gen = 200$
- broj opservacija, $br_ops = 5$
- vjerojatnost pojave križanja, $p_kri = 0.8$
- vjerojatnost pojave mutacije, $p_mut = 0.12$


Nasumično je generirana početna populacija od 30 jedinki. Svaka jedinka (kromosom) sastoji se od šest gena. Pritom, svaki gen predstavlja određenu varijablu odlučivanja, kako slijedi:

- prvi gen - veličina jedinične serije proizvoda D,
- drugi gen - veličina jedinične serije proizvoda E,
- treći gen - veličina jedinične serije proizvoda F,
- četvrti gen - vjerojatnost ulaska u sustav jedinične serije proizvoda D,
- peti gen - vjerojatnost ulaska u sustav jedinične serije proizvoda E,
- šesti gen - vjerojatnost ulaska u sustav jedinične serije proizvoda F.

Vrsta optimizacijskog zadatka ovog istraživanja je zadatak dodjele. Prema tome, za rješavanje ovog problema određenom genu se dodjeljuje nasumična vrijednost, kako slijedi:

- prema izrazu 5.2, za gen veličine jedinične serije (lota) proizvoda,
- prema izrazu 5.3, za gen vjerojatnosti ulaska određene jedinične serije proizvoda.

Na slici 6.14. mogu se vidjeti postavljeni rubni uvjeti za definirane varijable odlučivanja. Rubni uvjeti za veličinu jedinične serije su postavljeni u intervalu $[1, q_j]$ ovisno o vrsti proizvoda, odnosno uključene su sve realno moguće kombinacije. S druge strane, rubni uvjeti za vjerojatnost ulaska jedinične serije određenog proizvoda postavljeni su u intervalu $[100, 1000]$. Razlog zašto je postavljen relativno velik raspon je u tome kako bi se proširio prostor pretraživanja s ciljem pronalaska optimalnog rješenja.



Slika 6.14. Rubni uvjeti varijabli odlučivanja - veličina jediničnih serija i vjerojatnost ulaska jediničnih serija proizvoda u sustav

Isporuka na vrijeme osnovni je uvjet koji treba biti zadovoljen. S isporukom na vrijeme izravno je povezan najraniji završetak proizvodnje. Ovim slučajem zapravo se provjerava postoji li mogućnost proizvodnje ugovorene količine proizvoda D, E i F u promatranom razdoblju. Ukoliko to nije moguće, potrebno je razmisliti o uvođenju treće smjene ili subote kao dodatnog radnog dana.

Funkcija cilja izračunava vrijednost završetka proizvodnje, a prikazana je kao:

$$fitness = C_{max} \cdot 0,1 + C_{max,fit} \quad (6.1)$$

Kako bi se genetski algoritam „odmaknuo“ od loših (nezadovoljavajućih) rješenja i „približio“ boljim rješenjima uvodi se svojevrсна kazna $C_{max,penalty}$ prema slici 6.15. Pri čemu se vrijednost $C_{max,fit}$ dodaje u funkciju cilja kao kaznena vrijednost. Ako je $C_{max,fit} = 0$, uvjet isporuke je zadovoljen i neće imati nikakav utjecaj na funkciju cilja, no ako je $C_{max,fit} > 0$ onda to znači da uvjet nije zadovoljen te će vrijednost funkcije cilja porasti, što će u konačnici rezultirati odmicanjem genetskog algoritma od loših rješenja.



Slika 6.15. Slučaj 1 - funkcija cilja

Vrijeme potrebno za izvođenje optimizacije je 1 sat i 47 minuta. Rezultati optimizacije prvog slučaja, slika 6.16., pokazuju da za vrijednosti $LotSize_D = 80$, $LotSize_E = 54$, $LotSize_F = 71$, $Red_D = 454$, $Red_E = 888$, $Red_F = 449$, najkraći završetak proizvodnog procesa je nakon 6:04:48:18. Može se primijetiti da su veličine jediničnih serija manje te da je vrijeme završetka proizvodnog procesa smanjeno za više od 11 sati nego što je to do sada bio slučaj.


	string	integer
	0	1
	Define Set	Allocation
1	LotSizeD	80
2	LotSizeE	54
3	LotSizeF	71
4	PercD	454
5	PercE	888
6	PercF	449

Slika 6.16. Slučaj 1 - rezultati optimizacije


Iz evolucijskog dijagrama, slika 6.17, mogu se vidjeti dobivena rješenja tijekom definiranog broja generacija. Također, primjećuje se da genetski algoritam relativno brzo pronalazi dovoljno dobro rješenje, no povećanim broja generacija pronalaze se još bolja rješenja.

Simulacija proizvodnog procesa za optimirane vrijednosti za rezultat daje redoslijed i termine ulaska pojedine jedinične serije proizvoda u sustav (slika 6.18.). Raspored dodjeljivanja jediničnih serija proizvodnim resursima prikazan je gantogramom na slici 6.19. Gantogramom

su prikazani termini dolaska određene jedinične serije proizvoda te njeno zadržavanje u pojedinoj fazi proizvodnje. Vrijedi napomenuti da je vremenski period aktivnog odvijanja proizvodnje označen sivom bojom, dok je period neradnih smjena (22:00-06:00 sati) i neradnih dana (subota, nedjelja i praznici) označen plavom bojom.




Slika 6.17. Slučaj 1 - evolucijski dijagram




Slika 6.18. Slučaj 1 - rezultati simulacije proizvodnog procesa za dobivene optimalne vrijednosti veličine i vjerojatnosti ulaska jediničnih serija

Poglavlje 6. Studija slučaja i rezultati eksperimentalnih istraživanja



Poglavlje 6. Studija slučaja i rezultati eksperimentalnih istraživanja



Slika 6.19. Slučaj 1 - gantogram dodjele jediničnih serija proizvoda D, E i F proizvodnim resursima u pojedinim fazama proizvodnje

6.3.2. Slučaj 2 - određivanje optimalnoga vremenskog iskorištenja za minimalne vrijednosti srednjeg ciklusa izrade i ukupnog pripremno-završnog vremena uz osnovni uvjet pravovremene isporuke

U drugom slučaju uvode se novi kriteriji koji se odnose na ciklus izrade i pripremno-završno vrijeme. Unesene su sljedeće vrijednosti parametara genetskog algoritma.


- broj članova populacije, $vel_pop = 50$
- broj generacija, $br_gen = 150$
- broj opservacija, $br_ops = 5$
- vjerojatnost pojave križanja, $p_kri = 0.8$
- vjerojatnost pojave mutacije, $p_mut = 0.15$

Kao i u prethodnom slučaju, jedinka se sastoji od šest gena. Pritom su prva tri gena rezervirana za veličinu jedinične serije proizvoda D, E i F, a određuju se prema izrazu 5.2. Prema izrazu 5.3. određuju se preostala tri gena vezana za vjerojatnost ulaska jedinične serije proizvoda D, E i F u sustav. Cilj proizvodnje ne mora nužno težiti najkraćem završetku određenog posla, što je obrađeno u slučaju 1. Veća je potreba proizvodnih poduzeća da je ciklus izrade što manji. Na taj način se osigurava da je proizvod što kraće razdoblje u proizvodnom procesu. Također, potreba je da je pripremno-završno vrijeme što manje, jer se u tom vremenu, kao što je ranije objašnjeno, ne doprinosi vrijednosti proizvoda. Ciklus izrade i pripremno-završno vrijeme imaju jako velik utjecaj jedan na drugoga tako da povećavajući jednog smanjuje se drugi i obratno. Kada se na sve to nadoda potreba za pravovremenom isporukom, optimizacija je izrazito važna. Prema tome izrazom 6.2., definirana je funkcija cilja. Kako bi se genetski algoritam odmaknuo od nezadovoljavajućih rješenja primjenjen je isti princip kao i u prošlom slučaju (slika 6.20.).

$$fitness = C_{max,fit} + \omega_D \cdot t_{SCI,D} + \omega_E \cdot t_{SCI,E} + \omega_F \cdot t_{SCI,F} + v_D \cdot t_{UPZ,D} + v_E \cdot t_{UPZ,E} + v_F \cdot t_{UPZ,F} \quad (6.2.)$$

Ispitivanjem utjecaja parametara optimizacije na konačan rezultat, zaključeno je da svaki od članova funkcije cilja kojem se poveća utjecaj značajno utječe i na krajnji rezultat. Temeljem tog iskustva da svaki od parametara optimizacije ima približno jednaku važnost, definiraju se jednaki težinski faktori za svaki od članova:

$$\omega_D = \omega_E = \omega_F = v_D = v_E = v_F = \frac{1}{6} \quad (6.3.)$$



Slika 6.20. Slučaj 2 - funkcija cilja

Primjer izračuna funkcije cilja za drugi slučaj temeljem dvije odabrane jedinke.

	$LotSize_D$	$LotSize_E$	$LotSize_F$	Red_D	Red_E	Red_F
Jedinka 1	55	152	88	236	199	304
Jedinka 2	90	66	95	530	910	415

Izvršenim simulacijskim eksperimentom za obje jedinke, dobivene su vrijednosti srednjeg ciklusa izrade i ukupnog pripremno-završnog vremena, kao i vrijeme završetka simulacije odnosno završetka proizvodnje. Sva vremena su dana u formatu dani:sati:minute:sekunde.

	SCI_D	SCI_E	SCI_F	UPZ_D	UPZ_E	UPZ_F	C_{max}
Jedinka 1	3:04:57:02	2:15:38:10	2:06:13:46	2:08:23:15	2:04:56:53	3:03:41:52	10:14:09:53
Jedinka 2	2:04:02:54	2:02:38:38	2:03:24:21	1:13:06:50	2:04:11:09	1:02:33:47	6:08:02:33

Uvrštavanjem u izraz prema slici 6.19., dobivene su sljedeće vrijednosti kazne za svaku jedinku.


Jedinka 1	$C_{max,penalty} = [(10:14:09:53 - 6:16:00:00) / 6:16:00:00] = 0,56 > 0$
	$C_{max,fit} = (1 + 0,56) \cdot (10:14:09:53 - 6:16:00:00) = 6:05:35:01$
Jedinka 2	$C_{max,penalty} = [(6:08:02:33 - 6:16:00:00) / 6:16:00:00] = -0,05 \leq 0$
	$C_{max,fit} = 0$

Nadalje, prema izrazu 6.2. izračunata je funkcija cilja.

$$\begin{aligned} \text{Jedinka 1} \quad \text{fitness} &= 6:05:35:01 + \frac{1}{6} \cdot 3:04:57:02 + \frac{1}{6} \cdot 2:15:38:10 + \frac{1}{6} \\ &\quad \cdot 2:06:13:46 + \frac{1}{6} \cdot 2:08:23:15 + \frac{1}{6} \cdot 2:04:56:53 + \frac{1}{6} \\ &\quad \cdot 3:03:41:52 = \mathbf{8:20:53:30} \end{aligned}$$

$$\begin{aligned} \text{Jedinka 2} \quad \text{fitness} &= 0 + \frac{1}{6} \cdot 2:04:02:54 + \frac{1}{6} \cdot 2:02:38:38 + \frac{1}{6} \cdot 2:03:24:21 + \frac{1}{6} \\ &\quad \cdot 1:13:06:50 + \frac{1}{6} \cdot 2:04:11:09 + \frac{1}{6} \cdot 1:02:33:47 \\ &= \mathbf{1:20:59:36} \end{aligned}$$

Postupak optimizacije je trajao 1 sat i 33 minute. Rezultati optimizacije prema kriteriju minimalnih vrijednosti srednjeg ciklusa izrade i minimalnih ukupnih pripremno-završnih vremena uz uvjet isporuke na vrijeme pokazuju da su vrijednosti varijabli odlučivanja ($LotSize_D = 89$, $LotSize_E = 60$, $LotSize_F = 95$, $Red_D = 520$, $Red_E = 925$, $Red_F = 410$) različite od prvog slučaja, slika 6.21. Evolucijski dijagram pokazuje, slikom 6.22., da genetski algoritam i u ovom slučaju brzo pronalazi dobra rješenja.




	string 0	integer 1
string	Define Set	Allocation
1	LotSizeD	89
2	LotSizeE	60
3	LotSizeF	95
4	PercD	520
5	PercE	925
6	PercF	410


Slika 6.21. Slučaj 2 - rezultati optimizacije

Simulacijski eksperiment za optimiranje vrijednosti za rezultat daje redoslijed i termine ulaska jediničnih serija proizvoda D, E i F u sustav, slika 6.23. Srednji ciklus izrade je neznatno povećan, ali zato je ukupno vrijeme pripreme i rasporema uvelike smanjeno. Također, može se primijetiti kako je vrijeme završetka proizvodnje nešto veće nego u prvom slučaju, ali da zadovoljava osnovni uvjet isporuke na vrijeme. Na taj način je osigurano optimalno vremensko

iskorištenje VLPS-a. Raspored dodjeljivanja jediničnih serija proizvoda D, E i F proizvodnim resursima u pojedinim fazama proizvodnje prikazan je gantogramom (slika 6.24.).




Slika 6.22. Slučaj 2 - evolucijski dijagram




Slika 6.23. Slučaj 2 - rezultati simulacije proizvodnog procesa za dobivene optimalne vrijednosti veličine i vjerojatnosti ulaska jediničnih serija

Poglavlje 6. Studija slučaja i rezultati eksperimentalnih istraživanja



Poglavlje 6. Studija slučaja i rezultati eksperimentalnih istraživanja



Slika 6.24. Slučaj 2 - gantogram dodjele jediničnih serija proizvoda D, E i F proizvodnim resursima u pojedinim fazama proizvodnje

6.3.3. Slučaj 3 - određivanje optimalnoga vremenskog iskorištenja za minimalne troškove proizvodnje i osnovni uvjet isporuke na vrijeme

Treći slučaj predstavlja problem s ekonomskog stajališta. Rješenje ovakve vrste problema često je najbitniji odgovor koji zanima poslodavca iz stvarne proizvodnje. Unesene vrijednosti parametara genetskog algoritma su sljedeće:


- broj članova populacije, $vel_pop = 50$
- broj generacija, $br_gen = 150$
- broj opservacija, $br_ops = 5$
- vjerojatnost pojave križanja, $p_kri = 0.85$
- vjerojatnost pojave mutacije, $p_mut = 0.15$

Kao i u prethodna dva slučaja, jedinka se sastoji od šest gena koji se određuju po istom principu. Prva tri gena predstavljaju veličinu jedinične serije j -tog proizvoda i određuje se prema izrazu 5.2. u rasponu $[1, q_j]$, dok se preostali geni koji predstavljaju vjerojatnost ulaska jedinične serije j -tog proizvoda određuju izrazom 5.3. u rasponu $[100, 1000]$.

Za razliku od drugog slučaja, u ovom slučaju nije potrebno da se proizvodi što ranije završe, niti da je ciklus izrade određene jedinične serije proizvoda što manji, nego je cilj da se ugovorena količina isporuči na vrijeme. Također poželjno je da proizvodi provedu više vremena u procesu, odnosno da se završe što kasnije (ali dovoljno rano da se osigura isporuka na vrijeme) kako bi što manje vremena proveli kao zaliha u skladištu gotovih proizvoda. Samim tim postoji mogućnost za smanjenjem ukupnih troškova proizvodnje. Stoga, treća funkcija cilja (izraz 6.4.) ovisna je o vrijednosti novčanih jedinica, a ne o vremenu (barem ne izravno) za razliku od prva dva slučaja.

Kao i u prethodnim slučajevima, genetski algoritam se na sličan način pokušava udaljiti od nezadovoljavajućih rješenja i približiti dobrim rješenjima, odnosno onima koja zadovoljavaju uvjet isporuke na vrijeme, upotrebom kazne $UTP_{penalty}$ (slika 6.25.). Pri čemu se vrijednost UTP_{fit} dodaje u funkciju cilja kao kaznena vrijednost. Kada je $UTP_{fit} = 0$ onda je uvjet isporuke osiguran, u suprotnom to nije slučaj.

$$fitness = UTP + UTP_{fit} \quad (6.4.)$$



Slika 6.25. Slučaj 3 - funkcija cilja


Postupak optimizacije trećeg slučaja izvršen je za 1 sat i 36 minuta. Rezultati optimizacije prema kriteriju minimalnih troškova proizvodnje uz osnovni uvjet isporuke na vrijeme pokazuju da su vrijednosti varijabli odlučivanja ($Lot_D = 86$, $Lot_E = 107$, $Lot_F = 145$, $Red_D = 809$, $Red_E = 906$, $Red_F = 418$) različite od prva dva slučaja, slika 6.26.

	string 0	integer 1
string	Define Set	Allocation
1	LotSizeD	86
2	LotSizeE	107
3	LotSizeF	145
4	PercD	809
5	PercE	906
6	PercF	418


Slika 6.26. Slučaj 3 - rezultati optimizacije

Evolucijskim dijagramom, slika 6.27., kao i u prethodna dva slučaja pokazuje se da algoritam brzo pronalazi dobra rješenja, dok se povećanjem broja generacija pronalaze još bolja rješenja. Izvođenjem simulacijskog eksperimenta za unesene optimalne vrijednosti veličine i vjerojatnosti ulaska jediničnih serija dobiveni su redoslijed i vremenski termini ulaska jediničnih serija proizvoda D, E i F u sustav (slika 6.28.), kao i vremenski termini dodjeljivanja jediničnih serija proizvodnim resursima u pojedinim fazama proizvodnje, slika 6.29. Vrijeme završetka proizvodnje veće je nego u prva dva slučaja, ali zadovoljava osnovni uvjet isporuke

na vrijeme. Promatrajući troškove proizvodnje može se primijetiti da su troškovi proizvodnje u prvom slučaju 389 979 n.j., u drugom slučaju 379 963 n.j., dok su u ovom slučaju najmanji i iznose 362 980 n.j. Usporedbom ovog slučaja s trenutnim stanjem (slika 6.13.), gdje su troškovi proizvodnje 570 081 n.j., vidljivo je smanjenje za 207 101 n.j., odnosno 36 %.




Slika 6.27. Slučaj 3 - evolucijski dijagram




Slika 6.28. Slučaj 3 - rezultati simulacije proizvodnog procesa za dobivene optimalne vrijednosti veličine i vjerojatnosti ulaska jediničnih serija

Poglavlje 6. Studija slučaja i rezultati eksperimentalnih istraživanja



Poglavlje 6. Studija slučaja i rezultati eksperimentalnih istraživanja



Slika 6.29. Slučaj 3 - gantogram dodjele jediničnih serija proizvoda D, E i F proizvodnim resursima u pojedinim fazama proizvodnje

Poglavlje 7: ZAKLJUČAK

Proizvodna poduzeća susreću se sa sve većim tržišnim izazovima koji proizlaze iz povećanja kompleksnosti proizvoda i povećanja različitih varijanti proizvoda uz promjenjive opsege proizvodnje. Kako bi proizvodna poduzeća egzistirala i ostala konkurentna na tržištu izrazito su važne aktivnosti planiranja proizvodnje. Pogotovo aktivnosti operativne pripreme proizvodnje kojima se određuje vremenski plan odvijanja proizvodnje i osiguravaju svi potrebni resursi.

Shodno tome, provedeno znanstveno istraživanje zasnovano je na spoznajama objavljenim u znanstvenoj i stručnoj literaturi u području operativnog planiranja proizvodnje, bazirajući se na problemima planiranja veličine jediničnih serija i planiranja redoslijeda ulaska jediničnih serija proizvoda u sustav, dvaju glavnih područja poboljšanja mjera uspješnosti. Pritom su upotrebljena saznanja i iskustva relevantnih teoretičara i praktičara iz navedenih područja. Razlog razmatranja ovih dvaju područja je taj što veličina i redoslijed ulaska jediničnih serija proizvoda direktno utječu na vrijeme završetka proizvodnje, a samim time i na troškove proizvodnje.

Kod proizvodnje tehnološki sličnih obitelji proizvoda u modelu VLPS-a ograničene fleksibilnosti s proizvodnim procesom koji se odvija u više segmenata uobičajena je visoka iskorištenost proizvodnog sustava što sužava mogućnost pronalaska ekonomičnog rješenja.

Ako se tome nadoda prisutnost pripremno-završnog vremena ovisnog o slijedu proizvoda, te raspoloživost proizvodnih kapaciteta i transportne opreme, problem planiranja veličine jediničnih serija i redoslijeda ulaska jediničnih serija proizvoda svrstava se među najteže kombinatorne probleme rješavanja. Sve navedeno ujedno predstavlja i proizvodnju u realnom sektoru.

Proizvodnju u realnom sektoru karakterizira velik broj različitih parametara koji uvjetuju redoslijed odvijanja aktivnosti u proizvodnom procesu. Prema tome, ovakve probleme rješavanja gotovo je nemoguće riješiti matematičkim metodama bez uvođenja velikih pojednostavljenja. Također, proizvodna poduzeća koriste razne metode, module i tehnike koji se baziraju na determinističkim algoritmima. Međutim, takvi algoritmi ne uključuju brojne nesigurnosti karakteristične za realno okruženje, poput kvara na stroju, pojave škarta, nepredviđenih čekanja i sličnog. Slijedom toga, s ciljem kvalitetnog opisivanja te prikazivanja proizvodnje u realnom sektoru što stvarnijom, razvijen je računalom potpomognuti simulacijski okvir.

Simulacijski okvir zapravo predstavlja novi pristup rješavanju problema planiranja veličine i redoslijeda ulaska jediničnih serija proizvoda na temelju integracije simulacije diskretnih događaja i optimizacijskog alata, genetskog algoritma. S jedne strane, simulacija diskretnih događaja omogućava izradu digitalnog modela stvarnog proizvodnog sustava te jednostavne naknadne izmjene bez ometanja rada stvarnog sustava, kao i mogućnost uključivanja nesigurnosti. S druge strane, genetskim algoritmom osigurava se relativno brz pronalazak dovoljno dobrog rješenja. Na taj način koriste se prednosti oba alata. Implementiranjem izrađenog matematičkog modela u razvijeni simulacijski okvir stvorena je podloga za razvoj znanstveno zasnovane metode. Takvim simulacijskim okvirom omogućeno je eksperimentiranje s računalnim matematičkim modelom fizikalnog sustava. Primjenom i razvijanjem procedura unutar genetskog algoritma omogućeno je određivanje optimalnog vremenskog iskorištenja VLPS-a.

Simulacijski model izrađen je po uzoru na VLPS iz realnog okruženja u okviru programskog paketa Tecnomatix Plant Simulation. Tijekom izrade simulacijskog modela VLPS-a provedena je sustavna provjera ispravnosti izrade modela. Isto tako, provedena su dva testa kako bi se potvrdila ispravnost dobivenih rezultata. Prvi test je pokazao da simulacijski model daje identična rješenja onim dobivenim matematičkim metodama. Drugi test je pokazao ispravnost

rezultata u vidu projiciranog vremena završetka proizvodnje. Razlika u vremenu završetka proizvodnje u realnom okruženju i onom u simulacijskom modelu je neznatna, točnije, iznosi 0.428 %. Pritom, treba imati na umu da je navedena razlika uzrokovana pojavom različitih nesigurnosti i varijacija definiranih ulaznih parametara, poput pojave škarta ili nejednolikog pripremno-završnog vremena.

Još jedan važan doprinos ovog istraživanja je razvijeni umjetni kromosom koji se sastoji od određenog broja gena, ovisno o broju različitih vrsta proizvoda. Pritom, za svaku vrstu proizvoda jedan gen rezerviran je za veličinu jedinične serije tog proizvoda, a drugi gen za vjerojatnost ulaska jedinične serije proizvoda u sustav. Kako je problem promatranja postavljen kao alokacijski tip zadatka, to označava da vrijednosti gena za veličinu jediničnih serija i gena za vjerojatnost ulaska jediničnih serija mogu poprimiti bilo koju vrijednost iz vanjskog skupa. Ovakav oblik umjetnog kromosoma omogućava genetskom algoritmu velik prostor pretraživanja te na taj način osigurava uspješniji pronalazak optimalnog (ili gotovo optimalnog) rješenja.

Također, u ovom istraživanju je predložena nova formulacija troškova proizvodnje koja uključuje troškove proizvodne opreme (obradni strojevi, kontrolna oprema, transportna sredstva), troškove alata, troškove škarta, troškove skladištenja, troškove energije, troškove repromaterijala, kao i troškove zakašnjele isporuke.

Kako bi se dokazala primjenjivost razvijenog simulacijskog okvira, provedena je studija slučaja za proizvodno poduzeće iz realnog sektora. Predložena hipoteza ovog istraživanja potvrđena je kroz tri pomoćne hipoteze, odnosno rezultati triju slučajeva pokazuju da razvijeni simulacijski okvir određuje optimalno vremensko iskorištenje VLPS-a. Ujedno time dovodi i do smanjenja troškova proizvodnje uz pravovremenu isporuku.

- Prvim slučajem potvrđena je mogućnost proizvodnje ugovorenih količina tri različite vrste tehnološki sličnih proizvoda u za to predviđeno vrijeme, odnosno osigurana je isporuka na vrijeme. Rezultati provedenih eksperimenata pokazuju da je moguće proizvodnju završiti za približno 10 sati ranije od predloženog.
- Drugim slučajem dokazana je mogućnost isporuke na vrijeme ugovorene količine tri različite vrste tehnološki sličnih proizvoda, a da pritom vrijednosti ciklusa izrade i ukupnog pripremno-završnog vremena budu što manje. Rezultati pokazuju da je vrijeme

završetka proizvodnje veće u odnosu na prvi slučaj, ali su ciklus izrade i ukupno pripremno-završno vrijeme manji. Time se odredilo optimalno vremensko iskorištenje promatranog VLPS-a.

- Trećim slučajem odredili su se minimalni troškovi proizvodnje ugovorenih količina tri različite vrste tehnološki sličnih proizvoda. Pritom je zadovoljen uvjet pravovremene isporuke. Rezultatima eksperimentalnih istraživanja utvrđeno je da je troškove proizvodnje moguće smanjiti za 207101 n.j., odnosno za 36 %, što dovodi do optimalnog vremenskog iskorištenja VLPS-a.

Znanstveni doprinos ogleda se u poboljšanom načinu planiranja veličine jediničnih serija i redoslijeda ulaska jediničnih serija proizvoda kroz računalom potpomognuto razvijeni simulacijski okvir koji omogućava kvalitetnije i prije svega jednostavnije planiranje i vođenje proizvodnje. Drugim riječima, simulacijski okvir na jednostavan i jasan način služi kao potpora za planiranje proizvodnje.

Rezultati istraživanja su primjenjivi u raznim proizvodnim okruženjima, pogotovo onim koji se bave proizvodnjom širokog asortimana tehnološki sličnih proizvoda. Isto tako, rezultati ovog istraživanja mogu se primijeniti u narednim istraživanjima vezanim za razvoj operativnog planiranja proizvodnje.

Buduća istraživanja potrebno je usmjeriti na uvođenje radnog osoblja u sustav, odnosno kakav je utjecaj uvođenja radnog osoblja na rezultat istraživanja te koliko je radnog osoblja potrebno za nesmetano odvijanje proizvodnje. Isto tako, predlaže se primjena simulacijskog okvira na proizvodnim sustavima s povratnom vezom.

LITERATURA

- [1] Ahmadizar, F., Farhadi, S. (2015). Single-machine batch delivery scheduling with job release dates, due windows and earliness, tardiness, holding and delivery costs, *Computers and Operations Research*, Vol. 53, 194-205, doi: 10.1016/j.cor.2014.08.012
- [2] Akyol, D.E., Bayhan, G.M. (2007). A review on evolution of production scheduling with neural networks, *Computers & Industrial Engineering*, Vol. 53, No. 1, 95–122, doi:10.1016/j.cie.2007.04.006
- [3] Alfares, H. (2011). A Production Planning Optimization Model for Maximizing Battery Manufacturing Profitability, *International Journal of Applied Industrial Engineering*, Vol. 1, No. 1, 55-63, doi: 10.4018/ijaie.2012010105
- [4] Allahverdi, A. (2015). The third comprehensive survey on scheduling problems with setup times/costs, *European Journal of Operational Research*, Vol. 246, No. 2, 345-378, doi:10.1016/j.ejor.2015.04.004
- [5] Andradottir, S. (1998). Simulation optimization, Chapter 9 in *Handbook of Simulation: Principles, Methodology, Advances, Applications, and Practice*, 307-333, John Wiley & Sons, Inc., New Jersey, USA, doi: 10.1002/9780470172445.ch9
- [6] April, J., Better, M., Glover, F., Kelly, J., Laguna, M. (2006). Enhancing Business Process Management with Simulation Optimization, In: *Proceedings of the 2006 Winter Simulation Conference*, doi:10.1109/wsc.2006.323141
- [7] Azadeh, A., Moghaddam, M., Geranmayeh, P., Naghavi, A. (2010). A flexible artificial neural network–fuzzy simulation algorithm for scheduling a flow shop with multiple processors, *The International Journal of Advanced Manufacturing Technology*, Vol. 50, No. 5, 699–715, doi:10.1007/s00170-010-2533-6
- [8] Bagheri, A., Zandieh, M. (2011). Bi-criteria flexible job-shop scheduling with sequence-dependent setup times - Variable neighborhood search approach, *Journal of Manufacturing Systems*, Vol. 30, No. 1, 8–15, doi:10.1016/j.jmsy.2011.02.004
- [9] Baker, K.R., Trietsch, D. (2009). *Principles of Sequencing and Scheduling*, John Wiley & Sons, Inc., New Jersey, doi: 10.1002/9780470451793

-
- [10] Balasubramanian, J., Grossmann, I.E. (2003). Scheduling optimization under uncertainty-an alternative approach, *Computers & Chemical Engineering*, Vol. 27, No. 4, 469-490, doi: 10.1016/s0098-1354(02)00221-1
- [11] Bangsow, S. (2010). *Manufacturing Simulation with Plant Simulation and SimTalk*, Springer-Verlag Berlin Heidelberg, Germany, doi: 10.1007/978-3-642-05074-9
- [12] Bangsow, S. (2020). *Tecnomatix Plant Simulation*, 2nd edition, Springer Nature Switzerland AG, Switzerland, doi:10.1007/978-3-030-41544-0
- [13] Banks, J., Carson, J.S.II, Nelson, B.L., Nicol, D.M. (2010). *Discrete-Event System Simulation*, 5th edition, Pearson Education, Inc., Upper Saddle River, New Jersey, USA
- [14] Beck, F.G., Glock, C.H. (2016). The impact of batch shipments on the economic lot scheduling problem, *Computers & Industrial Engineering*, Vol. 96., 126-139, doi: 10.1016/j.cie.2016.02.021
- [15] Beemsterboer, B., Land, M., Teunter, R. (2017). Flexible lot sizing in hybrid make-to-order/make-to-stock production planning, *European Journal of Operational Research*, Vol. 260, No. 3, 1014-1023, doi: 10.1016/j.ejor.2017.01.015
- [16] Blum, C. (2005). Ant colony optimization: Introduction and recent trends, *Physics of Life Reviews*, Vol. 2, No. 4, 353–373, doi:10.1016/j.plrev.2005.10.001
- [17] Božikov, J. (2007). Modeliranje i simulacija, poglavlje u knjizi *Medicinskoinformatičke metode*, Medicinski fakultet Sveučilišta u Zagrebu i Medicinska Naklada, Zagreb, 85-108
- [18] Brajković, T., Perinić, M., Ikonić, M. (2018). Production Planning and Optimization of Work Launch Orders Using Genetic Algorithm, *Technical Gazette*, Vol. 25, No. 5, 1278-1285, doi: 10.17559/TV-20161207195125
- [19] Caggiano, A., Bruno, G., Teti, R. (2015). Integrating optimisation and simulation to solve manufacturing scheduling problems, *Procedia CIRP*, Vol. 28, 131-136, doi: 10.1016/j.procir.2015.04.022
- [20] Carson, Y., Maria, A. (1997). Simulation optimization, In: *Proceedings of the 29th Conference on Winter Simulation - WSC '97*, 118-126, doi:10.1145/268437.268460
- [21] Cavalieri, S., Gaiardelli, P. (1998). Hybrid genetic algorithms for a multiple-objective scheduling problem, *Journal of Intelligent Manufacturing*, Vol. 9, 361-367, doi: 10.1023/A:1008935027685
-

-
- [22] Chen, B. (1995). Analysis of Classes of Heuristics for Scheduling a Two-Stage Flow Shop with Parallel Machines at One Stage, *Journal of Operational Research Society*, Vol. 46, No. 2, 234-244, doi: 10.1057/jors.1995.28
- [23] Chen, F., Song, K. (2009). Minimizing makespan in two-stage hybrid cross docking scheduling problem, *Computers & Operations Research*, Vol. 36, No. 6, 2066–2073, doi: 10.1016/j.cor.2008.07.00
- [24] Cheng, B.Y., Leung, J.Y.T., Li, K. (2017). Integrated scheduling on a batch machine to minimize production, inventory and distribution costs, *European Journal of Operational Research*, Vol. 258, No. 1, 104-112, doi: 10.1016/j.ejor.2016.09.009
- [25] Cheng, M., Mukherjee, N.J., Sarin, S.C. (2013). A review of lot streaming, *International Journal of Production Research*, Vol. 51, No. 23-24, 7023-7046, doi: 10.1080/00207543.2013.774506
- [26] Chowdhury, N.T., Baki, M.F., Azab, A. (2018). Dynamic economic lot-sizing problem: a new O(T) algorithm for Wagner-within model, *Computers & Industrial Engineering*, Vol. 117, 6-18, doi: 10.1016/j.cie.2018.01.010
- [27] Conway, R.W., Maxwell, W.L., Miller, L.W. (2003). *Theory of Scheduling*, Illustrated edition, Dover Publications, New York
- [28] Čerić, V. (1993). *Simulacijsko modeliranje*, Školska knjiga, Zagreb, RH
- [29] Dai, M., Tang, D., Giret, A., Salido, M.A., Li, W.D. (2013). Energy-efficient scheduling for a flexible flow shop using an improved genetic-simulated annealing algorithm, *Robotics and Computer-Integrated Manufacturing*, Vol. 29, No. 5, 418-429, doi: 10.1016/j.rcim.2013.04.001
- [30] Demir, H.I., Uygun, O., Cil, I., Ipek, M., Sari, M. (2015). Process planning and scheduling with SLK due-date assignment where earliness, tardiness and due-dates are punished, *Journal of Industrial and Intelligent Information*, Vol. 3, No. 3, 173-180, doi: 10.12720/jiii.3.3.173-180
- [31] Dong, S., Medeiros, D.J. (2012). Minimising schedule cost via simulation optimisation: an application in pipe manufacturing, *International Journal of Production Research*, Vol. 50, No. 3, 831-841, doi: 10.1080/00207543.2010.545447
- [32] Dorigo, M., Maniezzo, V., Coloni, A. (1996). Ant system: optimization by a colony of cooperating agents, *IEEE Transactions on Systems, Man and Cybernetics - Part B (Cybernetics)*, Vol. 26, No. 1, 29-41, doi:10.1109/3477.484436
-

-
- [33] Dreio, J., Petrowski, A., Siarry, P., Taillard, E. (2006). *Metaheuristics for Hard Optimization*, Springer-Verlag Berlin Heidelberg, Germany
- [34] Drexler, A., Kimms, A. (1997). Lot sizing and scheduling - Survey and extensions, *European Journal of Operational Research*, Vol. 99, 221-235, doi: 10.1016/S0377-2217(97)00030-1
- [35] Dušak V. (1992). Simulacijsko modeliranje u procesu odlučivanja, *Journal of Information and Organizational Sciences*, No. 16, 65-71, preuzeto s <https://hrcak.srce.hr/79719> [Citirano: 10.01.2021.]
- [36] Esmaeilian, B., Behdad, S., Wang, B. (2016). The evolution and future of manufacturing: A review, *Journal of Manufacturing Systems*, Vol. 39, 79-100, doi: 10.1016/j.jmsy.2016.03.001
- [37] Fishman, G.S. (2001). *Discrete-Event Simulation*, Springer Science+Business Media, New York, USA, doi:10.1007/978-1-4757-3552-9
- [38] Framinan, J.M., Leisten, R., Ruiz, G.R. (2014). *Manufacturing Scheduling Systems: An Integrated View on Models, Methods and Tools*, Springer-Verlag, UK, doi: 10.1007/978-1-4471-6272-8
- [39] Frantzen, M. (2013). *A real-time simulation-based optimisation environment for industrial scheduling*, PhD, De Monfort University, Leicester, UK, preuzeto s https://www.dora.dmu.ac.uk/xmlui/bitstream/handle/2086/9032/Marcus_Frantzen_Thesis.pdf?sequence=1&isAllowed=y, [Citirano 11. 11. 2020.]
- [40] Gajsek, B., Marolt, J., Rupnik, B., Lerher, T., Sternad, M. (2019). Using Maturity Model and Discrete-Event Simulation for Industry 4.0 Implementation, *International Journal of Simulation Modelling*, Vol. 18, No. 3, 488-499, doi: 10.2507/IJSIMM18(3)489
- [41] Gao, J., Chen, R., Deng, W. (2013). An efficient tabu search algorithm for the distributed permutation flowshop scheduling problem, *International Journal of Production Research*, Vol. 51, No. 3, 641–651, doi:10.1080/00207543.2011.644819
- [42] Garey, M.R., Johnson, D.S., Sethi, R. (1976). The Complexity of Flowshop and Jobshop Scheduling, *Mathematics of Operations Research*, Vol. 1, No. 2, 117–129, doi: 10.1287/moor.1.2.117
- [43] Gen, M., Cheng, R. (1997). *Genetic Algorithms and Engineering Design*, John Wiley & Sons, New Jersey, USA
-

-
- [44] Georgiadis, G.P., Elekidis, A.P., Georgiadis, M.C. (2019). Optimization-Based Scheduling for the Process Industries: From Theory to Real-Life Industrial Applications, *Processes*, Vol. 7, No. 7: 438, doi:10.3390/pr7070438
- [45] Goldberg, D.E. (1989). *Genetic Algorithms in Search, Optimization, and Machine Learning*, Addison-Wesley Publishing Company, Inc., Reading, Massachusetts, USA
- [46] Gordon, G. (1978.). *System simulation*, 2nd edition, Englewood Cliffs, Prentice-Hall, New Jersey, USA
- [47] Graves, S.C. (1981). A Review of Production Scheduling, *Operation Research*, Vol. 29, No. 4, 646-675, doi: 10.1287/opre.29.4.646
- [48] Gupta, Y., Gupta, M., Kumar, A., Sundaram, C. (1996). A genetic algorithm-based approach to cell composition and layout design problems, *International Journal of Production Research*, Vol. 34, No. 2, 447–482, doi:10.1080/00207549608904913
- [49] Hamta, N., Akbarpour Shirazi, M., Fatemi Ghomi, S.M.T., Behdad, S. (2014). Supply chain network optimization considering assembly line balancing and demand uncertainty, *International Journal of Production Research*, Vol. 53, No. 10, 2970-2994, doi: 10.1080/00207543.2014.978030
- [50] Harrell, C., Ghosh, B.K., Bowden, R. (2004). *Simulation using ProModel*, 2nd edition, McGraw-Hill/Higher Education, Boston, USA
- [51] Hendizadeh, S.H., Elmekawy, T., Wang, G. (2007). Bi-criteria scheduling of a flowshop manufacturing cell with sequence dependent setup times, *European Journal of Industrial Engineering*, Vol. 1, No. 4, 391-413, doi: 10.1504/EJIE.2007.015388
- [52] Hill, T. (1995). *Manufacturing Strategy: Text and Cases*, 2nd edition, Macmillan Press Ltd, London, doi: 10.1007/978-1-349-13724-4
- [53] Holland, J. (1975). *Adaptation in Natural and Artificial Systems*, University of Michigan Press, Ann Arbor
- [54] Ištoković, D., Perinić, M., Doboviček, S., Bazina, T. (2019a). Simulation framework for determining the order and size of the product batches in the flow shop: A case study, *Advances in Production Engineering & Management*, Vol. 14, No. 2, 166-176, doi: 10.14743/apem2019.2.319
- [55] Ištoković, D., Perinić, M., Jurković, Z. (2019b). Minimizing the makespan in the flowshop with sequence-dependent setup times: simulation approach, In: *Proceedings of*
-

-
- 9th International Conference "Mechanical Technologies and Structural Materials" MTSM 2019, Split, 77-82
- [56] Ištoković, D., Perinić, M., Vlatković, M., Brezočnik, M. (2020). Minimizing total production cost in a hybrid flow shop: a simulation-optimization approach, *International Journal of Simulation Modelling*, Vol. 19, No. 4, 559-570, doi: 10.2507/IJSIMM19-4-525
- [57] Jahangirian, M., Eldabi, T., Naseer, A., Stergioulas, L.K., Young, T. (2010). Simulation in manufacturing and business: A review, *European Journal of operational Research*, Vol. 203, No. 1, 1-13, doi: 10.1016/j.ejor.2009.06.004
- [58] Jiang, S.L., Zhang, L. (2019). Energy-Oriented Scheduling for Hybrid Flow Shop With Limited Buffers Through Efficient Multi-Objective Optimization, *IEEE Access*, Vol. 7, 34477–34487. doi:10.1109/access.2019.2904848
- [59] Johansson, B., Kacker, R., Kessel, R., McLean, C., Sriram, R. (2009). Utilizing Combinatorial Testing on Discrete Event Simulation Models for Sustainable Manufacturing, In: *Volume 2: 29th Computers and Information in Engineering Conference, Parts A and B*, 1-7, doi: 10.1115/detc2009-86522
- [60] Kliment, M., Trebuna, P., Pekarcikova, M., Straka, M., Trojan, J., Duda, R. (2020). Production efficiency evaluation and products' quality improvement using simulation, *International Journal of Simulation Modelling*, Vol. 19, No.3, 470-481, doi: 10.2507/IJSIMM19-3-528
- [61] Kuo, Y., Yang, T., Cho, C., Tseng, Y.C. (2008). Using simulation and multi-criteria methods to provide robust solutions to dispatching problems in a flow shop with multiple processors, *Mathematics and Computers in Simulation*, Vol. 7, No. 1, 40–56, doi: 10.1016/j.matcom.2007.06.002
- [62] Langer, R., Li, J., Biller, S., Chang, Q., Huang, N., Xiao, G. (2010). Simulation study of a bottleneck-based dispatching policy for a maintenance workforce, *International Journal of Production Research*, Vol. 48, No. 6, 1745–1763, doi: 10.1080/00207540802555769
- [63] Law, A.M., Kelton, W.D. (1991). *Simulation Modelling and Analysis*, 2nd edition, McGraw-Hill, Inc., Singapore
- [64] Li, Q., Milne, J.R. (2014). A production scheduling problem with sequence-dependent changeover costs, *International Journal of Production Research*, Vol. 52, No. 13, 4093-4102, doi: 10.1080/00207543.2014.889860
-

-
- [65] Lin, S.W., Ying, K.C. (2012). Scheduling a bi-criteria flowshop manufacturing cell with sequence dependent family setup times, *European Journal of Industrial Engineering*, Vol. 6, No. 4, 474-496, doi: 10.1504/ejie.2012.047666
- [66] Liu, J., Li, C., Yang, F., Wan, H., Uzsoy, R. (2011). Production planning for semiconductor manufacturing via simulation optimization, In: *Proceedings of the 2011 Winter Simulation Conference (WSC)*, 3612-3622, doi: 10.1109/WSC.2011.6148055
- [67] Mendez, C.A., Cerda, J., Grossmann, I. E., Harjunkski, I., Fahl, M. (2006). State-of-the-art review of optimization methods for short-term scheduling of batch processes, *Computers and Chemical Engineering*, Vol. 30, 913-946, doi: 10.1016/j.compchemeng.2006.02.008
- [68] Metaxiotis, K.S., Askounis, D., Psarras, J. (2002). Expert systems in production planning and scheduling: A state-of-the-art survey, *Journal of Intelligent Manufacturing*, Vol. 13, No. 4, 253-260, doi: 10.1023/a:1016064126976
- [69] Michalewicz, Z., Fogel, D.B. (2004). *How to Solve It: Modern Heuristics*, Second, Revised and Extended Edition, Springer-Verlag Berlin Heidelberg, doi: 10.1007/978-3-662-07807-5
- [70] Mikac, T., Ikonić, M. (2008). *Organizacija poslovnih sustava*, Graphis, Zagreb, RH
- [71] Mikac, T., Ikonić, M. (2013.). Tehnološka priprema proizvodnje, poglavlje 8 u knjizi *Menadžment životnim ciklusom proizvoda*, Fakultet tehničkih nauka Univerziteta u Novom Sadu, Novi Sad, 267-336
- [72] Modrak, V., Soltysova, Z. (2020). Batch size optimization of multi-stage flow lines in terms of mass customization, *International Journal of Simulation Modelling*, Vol. 19, No. 2, 219-230, doi: 10.2507/IJSIMM19-2-511
- [73] Montevechi, J.A.B., Miranda, R. de C., Friend, J.D. (2012). Sensitivity Analysis in Discrete Event Simulation Using Design of Experiments, Chapter 3 in book *Discrete Event Simulations - Development and Applications*, Eldin Wee Chuan Lim, IntechOpen, 63-102, doi: 10.5772/50196
- [74] Mourtzis, D. (2019). Simulation in the design and operation of manufacturing systems: state of the art and new trends, *International Journal of Production Research*, Vol. 58, No. 3, 1–23, doi:10.1080/00207543.2019.1636321
-

-
- [75] Naderi, B., Zandieh, M., Fatemi Ghomi, S.M. (2009). Scheduling sequence-dependent setup time job shops with preventive maintenance, *The International Journal of Advanced Manufacturing Technology*, Vol. 43 No. 1, 170-181, doi: 10.1007/s00170-008-1693-0
- [76] Negahban, A., Smith, J.S. (2014). Simulation for manufacturing system design and operation: literature review and analysis, *Journal of Manufacturing Systems*, Vol. 33, No. 2, 241-261, doi:10.1016/j.jmsy.2013.12.007
- [77] Nicholas, J.M. (2008). *Competitive Manufacturing Management: Continuous Improvement, Lean Production and Customer-Focused Quality*, 3rd edition, McGraw-Hill, New York, USA
- [78] Novas, J.M. (2019). Production scheduling and lot streaming at flexible job shops environments using constraint programming, *Computers & Industrial Engineering*, Vol. 136, 252-264, doi: 10.1016/j.cie.2019.07.011
- [79] Ochoa, G., Vazquez-Rodriguez, J.A., Petrovic, S., Burke, E. (2009). Dispatching rules for production scheduling: A hyper-heuristic landscape analysis, In: *IEEE Congress on Evolutionary Computation*, 1873-1880, doi:10.1109/cec.2009.4983169
- [80] Osmanagić-Bedenik, N. (2012). *Operativno planiranje*, Školska knjiga, Zagreb, RH
- [81] Pardalos, P.M., Du, D.Z., Graham, R.L. (2013). *Handbook of Combinatorial Optimization*, 2nd edition, Springer Science+Business Media, New York, doi: 10.1007/978-1-4419-7997-1
- [82] Pekarcikova, M., Trebuna, P., Kliment, M., Rosocha, L. (2020). Material Flow Optimization through E-Kanban System Simulation, *International Journal of Simulation Modelling*, Vol. 19, No. 2, 243-254, doi: 10.2507/IJSIMM19-2-513
- [83] Perinić, M. (2004). *Optimizacija ciklusa izrade na fleksibilnom proizvodnom sustavu primjenom genetskih algoritama*, Doktorski rad, Tehnički fakultet, Rijeka, RH
- [84] Perinić, M., Ljubetić, J. (2001). A genetic algorithm for working orders sequencing, In: *Proceedings of the 8th International Scientific – Technical Conference on Internal Combustion Engines and Motor Vehicles*, MOTAUTO 01, Vol. I, Varna, 83 – 85
- [85] Perinić, M., Mikac, T., Maričić, S. (2008). Optimizing Time Utilization of FMS, *Strojarstvo*, Vol. 50, No. 6., 353-362, preuzeto s <https://hrcak.srce.hr/40655> [Citirano: 12.01.2021.]
-

-
- [86] Philipoom, P.R. (2000). The choice of dispatching rules in a shop using internally set due-dates with quoted leadtime and tardiness costs, *International Journal of Production Research*, Vol. 38, No. 7, 1641-1655, doi: 10.1080/002075400188771
- [87] Pinedo, M.L. (2005). *Planning and scheduling in manufacturing and services*, Springer Science + Business Media, Inc., New York, USA, doi: 10.1007/b139030
- [88] Pinedo, M.L. (2016). *Scheduling: Theory, algorithms and systems*, 5th edition, Springer, New York, USA, doi:10.1007/978-3-319-26580-3
- [89] Rajkumar, M., Asokan, P., Page, T., Arunachalam, S. (2010). A GRASP algorithm for the Integration of Process Planning and Scheduling in a flexible job-shop, *International Journal of Manufacturing Research*, Vol. 5, No. 2, 230-251, doi: 10.1504/ijmr.2010.031633
- [90] Ramya, R., Rajendran, C., Ziegler, H., Mohapatra, S., Ganesh, K. (2019). *Capacitated Lot Sizing Problems in Process Industries*, Springer Nature Switzerland AG, doi: 10.1007/978-3-030-01222-9
- [91] Rauf, M., Guan, Z., Sarfraz, S., Mumtaz, J., Shebab, E., Jahanzaib, M., Hanif, M. (2020). A smart algorithm for multi-criteria optimization of model sequencing problem in assembly lines, *Robotics and Computer Integrated Manufacturing*, Vol. 61, doi: 10.1016/j.rcim.2019.101844
- [92] Ribas, I., Companys, R., Tort-Martorell, X. (2011). An iterated greedy algorithm for the flowshop scheduling problem with blocking, *Omega*, Vol. 39, No. 3, 293–301, doi: 10.1016/j.omega.2010.07.007
- [93] Ribas, I., Leisten, R., Framiñan, J.M. (2010). Review and classification of hybrid flow shop scheduling problems from a production system and a solutions procedure perspective, *Computers & Operations Research*, Vol. 37, No. 8, 1439-1454, doi: 10.1016/j.cor.2009.11.001
- [94] Robinson, S. (2004). *Simulation: The Practice of Model Development and Use*, John Wiley & Sons, New York
- [95] Rossit, D.A., Tohme, F., Frutos, M. (2018). The Non-Permutation Flow-Shop scheduling problem: A literature review, *Omega*, Vol. 77, 143-153, doi: 10.1016/j.omega.2017.05.010
- [96] Ryan, J., Heavey, C. (2006). Process modeling for simulation, *Computers in Industry*, Vol. 57, No. 5, 437-450, doi: 10.1016/j.compind.2006.02.002
-

-
- [97] Schmidt, J.W., Taylor, R.E. (1970). *Simulation and Analysis of Industrial Systems*, Richard D. Irwin, Inc., Homewood, USA
- [98] Schroeder, R.G. (1993). *Upravljanje proizvodnjom*, 4th edition, Mate, Zagreb, RH
- [99] Schulz, S., Neufeld, J.S., Buscher, U. (2019). A multi-objective iterated local search algorithm for comprehensive energy-aware hybrid flow shop scheduling, *Journal of Cleaner Production*, Vol. 224, 421-434, doi: 10.1016/j.jclepro.2019.03.155
- [100] Seila, A., Čerić, V., Tadikamalla, P. (2003). *Applied Simulation Modeling*, Brooks/Cole-Thomson Learning, Belmont, CA
- [101] Sharma, P., Jain, A. (2014). Analysis of dispatching rules in a stochastic dynamic job shop manufacturing system with sequence-dependent setup times, *Frontiers of Mechanical Engineering*, Vol. 9, No. 4, 380-389, doi: 10.1007/s11465-014-0315-9
- [102] Sharma, P., Jain, A. (2015). Performance analysis of dispatching rules in a stochastic dynamic job shop manufacturing system with sequence-dependent setup times: Simulation approach, *CIRP Journal of Manufacturing Science and Technology*, Vol. 10, 110-119, doi:10.1016/j.cirpj.2015.03.003
- [103] Shi, L., Guo, G., Song, X. (2021). Multi-agent based dynamic scheduling optimisation of the sustainable hybrid flow shop in a ubiquitous environment, *International Journal of Production Research*, Vol. 59, No. 2, 576-597, doi: 10.1080/00207543.2019.1699671
- [104] Shibin, K.T., Gunasekaran, A., Papadopoulos, T., Childe, S.J., Dubey, R., Singh, T. (2016). Energy sustainability in operations: an optimization study, *The International Journal of Advanced Manufacturing Technology*, Vol. 86, 2873-2884, doi: 10.1007/s00170-016-8398-6
- [105] Sox, C.R., Jackson, P.L., Bowman, A., Muckstadt, J.A. (1999). A review of the stochastic lot scheduling problem, *International Journal of Production Economics*, Vol. 62, No. 3, 181-200, doi: 10.1016/s0925-5273(98)00247-3
- [106] Stawowy, A., Duda, J. (2017). Iterated local search for foundry lot-sizing and scheduling problem with setup costs, *Archives of Foundry Engineering*, Vol.17, No. 4, 161-164, doi: 10.1515/afe-2017-0150
- [107] Talbi, E.G. (2009.), *Metaheuristics: From Design to Implementation*, John Wiley & Sons, Inc., Hoboken, New Jersey, USA
- [108] T'Kindt, V., Monmarche, N., Tercinet, F., Laugt, D. (2002). An Ant Colony optimization algorithm to solve a 2-machine bicriteria flowshop scheduling problem, *International*
-

-
- Journal of Production Research*, Vol. 142, No. 2, 250-257, doi: 10.1016/s0377-2217(02)00265-5
- [109] Trigos, F., Lopez, E.M. (2016). Maximising profit for multiple-product, single-period, single-machine manufacturing under sequential set-up constraints that depend on lot size, *International Journal of Production Research*, Vol. 54, No. 4, 1134-1151, doi: 10.1080/00207543.2015.1055348
- [110] Vaidyanathan, B.S., Miller, D.M., Park, Y.H. (1998). Application of discrete event simulation in production scheduling, In: *Proceedings of the 1998 Winter Simulation Conference*, 965-971, doi:10.1109/wsc.1998.745800
- [111] Vinod, K.T., Prabakaran, S., Joseph, O.A. (2017). Dynamic due date assignment method: A simulation study in a job shop with sequence-dependent setups, *Journal of Manufacturing Technology Management*, Vol. 30, No. 6, 987-1003, doi: 10.1108/JMTM-06-2017-0112
- [112] Vinod, V., Sridharan, R. (2008). Dynamic job-shop scheduling with sequence-dependent setup times: simulation modeling and analysis, *International Journal of Advanced Manufacturing Technology*, Vol. 36, No. 3-4, 355-372, doi: 10.1007/s00170-006-0836-4
- [113] Voutsinas, T.G., Pappis, C.P. (2010). A branch and bound algorithm for single machine scheduling with deteriorating values of jobs, *Mathematical and Computer Modelling*, Vol. 52, No. 1-2, 55–61, doi:10.1016/j.mcm.2009.12.024
- [114] Wang, Q., Liu, S., Gao, B., Wang, D. (2009). A framework model of production planning optimization for make-to-order discrete manufacturing, In: *Chinese Control and Decision Conference (CCDC 2009)*, 2516-2520, doi: 10.1109/ccdc.2009.5191920
- [115] Wiendahl, H.P., Reichardt, J., Nyhuis, P. (2015). *Handbook Factory Planning and Design*, Springer-Verlag Berlin Heidelberg, doi:10.1007/978-3-662-46391-8
- [116] Winston, W.L., Goldberg, J.B. (2004). *Operations Research: Applications and Algorithms*, 4th edition, Thomson Brooks/Cole, Canada
- [117] Wohlgemuth, V., Page, B., Kreutzer, W. (2006). Combining discrete event simulation and material flow analysis in a component-based approach to industrial environmental protection, *Environmental Modelling & Software*, Vol. 21, No. 11, 1607–1617, doi: 10.1016/j.envsoft.2006.05.015
-

-
- [118] Xing, L.N., Chen, Y.W., Wang, P., Zhao, Q.S., Xiong, J. (2010). A Knowledge-Based Ant Colony Optimization for Flexible Job Shop Scheduling Problems, *Applied Soft Computing*, Vol. 10, No. 3, 888–896, doi:10.1016/j.asoc.2009.10.006
- [119] Xu, L.D., Xu, E.L., Li, L. (2018). Industry 4.0: state of the art and future trends, *International Journal of Production Research*, Vol. 56, No. 8, 2941-2962, doi: 10.1080/00207543.2018.1444806
- [120] Yang, S.L., Xu, Z.G., Li, G.Z., Wang, J.Y. (2020). Assembly transport optimization for a reconfigurable flow shop based on a discrete event simulation, *Advances in Production Engineering & Management*, Vol. 15, No. 1, 69-80, doi: 10.14743/apem2020.1.350
- [121] Yilmaz, O.F., Cevikcan, E., Durmusoglu, M.B. (2016). Scheduling batches in multi hybrid cell manufacturing system considering worker resources: A case study from pipeline industry, *Advances in Production Engineering & Management*, Vol. 11, No. 3, 192-206, doi: 10.14743/apem2016.3.220
- [122] Yin, Y., Cheng, T.C.E., Wang, J., Wu, C.C. (2013). Single-machine common due window assignment and scheduling to minimize the total cost, *Discrete Optimization*, Vol. 10, No. 1, 42-53, doi: 10.1016/j.disopt.2012.10.003
- [123] Yu, G., Chai, T., Luo, X. (2011). Multiobjective Production Planning Optimization Using Hybrid Evolutionary Algorithms for Mineral Processing, *IEEE Transactions on Evolutionary Computation*, Vol. 15, No. 4, 487–514, doi: 10.1109/tevc.2010.2073472
- [124] Zhang, C., Li, P., Guan, Z., Rao, Y. (2007). A tabu search algorithm with a new neighborhood structure for the job shop scheduling problem, *Computers & Operations Research*, Vol. 34, No. 11, 3229–3242, doi:10.1016/j.cor.2005.12.002
- [125] Zhang, H., Zhao, F., Fang, K., Sutherland, J.W. (2014). Energy-conscious flow shop scheduling under time-of-use electricity tariffs, *CIRP Annals - Manufacturing Technology*, Vol. 63, No. 1, 37-40, doi: 10.1016/j.cirp.2014.03.011
- [126] Zhang, J., Wang, X., Huang, K. (2016). Integrated on-line scheduling of order batching and delivery under B2C e-commerce, *Computers & Industrial Engineering*, Vol. 94, 280-289, doi: 10.1016/j.cie.2016.02.001
- [127] Zhang, Z., Wang, X., Wang, X., Cui, F., Cheng, H. (2019). A simulation-based approach for plant layout design and production planning, *Journal of Ambient Intelligence and Humanized Computing*, Vol. 10, No. 3, 1217-1230, doi: 10.1007/s12652-018-0687-5
-

- [128] Hrvatska enciklopedija, preuzeto s <https://www.enciklopedija.hr/natuknica.aspx?ID=48598>, [Citirano: 10. siječnja 2021.]
- [129] Hrvatska enciklopedija, preuzeto s <https://www.enciklopedija.hr/natuknica.aspx?id=25317>, [Citirano: 10. siječnja 2021.]
- [130] Hrvatska enciklopedija, preuzeto s <https://www.enciklopedija.hr/natuknica.aspx?id=2341>, [Citirano: 10. siječnja 2021.]
- [131] Newcastle University, Engineering Design Centre, preuzeto s <http://www.edc.ncl.ac.uk/highlight/rhjanuary2007g02.php>, [Citirano: 10. siječnja 2021.]

POPIS OZNAKA I KRATICA

Latinični simboli:

AV_k	amortizacijska vrijednost kontrolne opreme k
AV_l	amortizacijska vrijednost transportnog sredstva l
AV_m	amortizacijska vrijednost proizvodnog kapaciteta (stroja) m
b	broj jediničnih serija određene vrste proizvoda
b_j	broj jediničnih serija proizvoda j
ba_a	broj utrošenih alata a
ba_{max}	maksimalan dopušteni broj utrošenih alata
br_{gen}	broj generacija
br_{ops}	broj opservacija
brk_u	vrijeme čekanja u uzrokovanog kvarog proizvodnog kapaciteta
C_j	vrijeme završetka proizvodnje proizvoda j
C_{max}	vrijeme završetka proizvodnje svih proizvoda
$C_{max,fit}$	kaznena vrijednost koja se dodaje u funkciju cilja
$C_{max,goal}$	raspoloživo vrijeme za izradu svih proizvoda
$C_{max,penalty}$	kazna uslijed neisporuke na vrijeme
$\check{c}_h$	vrijeme h -tog čekanja jedinice proizvoda na red za izradu
$\check{c}_f$	vrijeme f -tog čekanja jedinične serije proizvoda na izradu
$\check{c}_g$	vrijeme g -tog čekanja jedinične serije proizvoda na transport
d	broj radnih dana
d_j	rok za završetak izrade proizvoda j
dg	donja granica
e_{bj}	vrijeme izlaska b -te jedinične serije proizvoda j iz sustava
E_k	količina utrošene električne energije kontrolne opreme k
E_l	količina utrošene električne energije transportnog sredstva l
E_m	količina utrošene električne energije proizvodnog kapaciteta m
f	funkcija cilja

gg	gornja granica
h	broj radnih sati
i	operacija
j	vrsta proizvoda
K_j	kašnjenje proizvoda j
k_k	vrijeme k -te kontrole
K_{max}	maksimalno kašnjenje
k_{PEN}	koeficijent zakašnjele isporuke
Lot_j	veličina jedinične serije proizvoda j
$Lot_{j,ost}$	veličina posljednje jedinične serije proizvoda j
Lot_{max}	maksimalna veličina jedinične serije
Lot_{min}	minimalna veličina jedinične serije
m	proizvodni kapacitet (stroj)
ms_s	vrijeme s -tog međuskladištenja
n	broj radnih zadataka
N_{am}	broj utrošenih alata a na proizvodnom kapacitetu m
o_i	vrijeme operacije i
o_{ij}	vrijeme operacije i nekog proizvoda j
p	pouzdanost
P_j	stopa penala za neisporuku proizvoda j
p_m	pouzdanost m -tog proizvodnog kapaciteta
$p_{\S}$	stopa pojave škarta
p_{kri}	vjerojatnost pojave križanja
p_{mut}	vjerojatnost pojave mutacije
pZ_{jk}	pripremno-završno vrijeme zbog dolaska proizvoda k nakon proizvoda j
pZ_m	pripremno-završno vrijeme m -tog proizvodnog kapaciteta
pZ_{mj}	pripremno-završno vrijeme proizvoda j na m -tom proizvodnom kapacitetu
q	ukupna proizvodna količina određene vrste proizvoda
q_j	ukupna proizvodna količina proizvoda j
r_{bj}	vrijeme ulaska b -te jedinične serije proizvoda j u sustav
R_j	prijevremenost završetka proizvodnje proizvoda j

r_j	vrijeme u kojem proizvod j ulazi u sustav
R_{max}	maksimalna prijevremenost završetka proizvodnje
Red_j	težinska vrijednost vjerojatnosti ulaska jedinične serije proizvoda j u sustav
s	broj radnih smjena
$\dot{s}_{ij}$	broj škartnih jedinica proizvoda j na operaciji i
t_0	početak proizvodnje
T_A	trošak alata
T_{am}	cijena alata a korištenog na proizvodnom kapacitetu m
t_{CI}	ciklus izrade
$t_{CI,j}$	ciklus izrade proizvoda j
$t_{\check{c}}$	vrijeme čekanja
T_E	trošak energije
T_e	cijena jedinične električne energije
T_{GP}	troškovi zaliha gotovih proizvoda
t_K	vrijeme kontrole
t_l	vrijeme l -tog transporta
t_{max}	vrijeme završetka promatranog razdoblja
t_{MS}	vrijeme međuskladištenja
t_N	vrijeme nepouzdanosti proizvodnih kapaciteta
T_{PO}	trošak proizvodne opreme
T_{PZ}	troškovi pripreme i raspoređivanja radnih mjesta
t_{PZ}	pripremno-završno vrijeme
T_{RPM}	trošak repromaterijala
$T_{rpm,j}$	cijena j -tog repromaterijala
T_S	trošak skladištenja
t_{SCI}	prosječna vrijednost ciklusa izrade
$t_{SCI,j}$	prosječna vrijednost ciklusa izrade proizvoda j
T_{SGP}	trošak skladištenja gotovih proizvoda
$T_{sgp,j}$	trošak držanja jedinice proizvoda j u skladištu gotovih proizvoda
T_{SRM}	trošak skladištenja repromaterijala
$T_{srm,j}$	trošak držanja jedinice proizvoda j u skladištu repromaterijala

T_{ξ}	trošak škarta
t_{ξ}	vrijeme izrade škartnih proizvoda
T_T	troškovi transporta
t_T	vrijeme transporta
t_{TC}	tehnološki ciklus
$t_{UPZ,j}$	ukupno pripremno-završno vrijeme proizvoda j
T_{WIP}	troškovi zaliha u radu
t_{ZA}	vrijeme zamjene svih alata
Th	propusnost
U	broj radnih zadataka nakon roka dospijeca
UTP	ukupan trošak proizvodnje
UTP_{fit}	kaznena vrijednost koja se dodaje u funkciju cilja
$UTP_{penalty}$	kazna uslijed neisporuke na vrijeme
v_l	brzina kretanja transportnog sredstva l
vel_pop	veličina populacije
x	ulazne varijable
y	izlazne varijable
$\bar{Z}$	prosječna zakašnjelost
Z_j	zakašnjenje proizvoda j
Z_{max}	maksimalno zakašnjenje
Z_{uk}	ukupna zakašnjelost
za_a	vrijeme zamjene alata a

Grčki simboli:

α	proizvodno okruženje
β	karakteristike i ograničenja izrade
γ	cilj razmatranja
η	broj ulaznih varijabli
θ	broj izlaznih varijabli
λ	duljina niza gena
v	težinska vrijednost za ukupno pripremno-završno vrijeme

ω težinska vrijednost za prosječnu vrijednost ciklusa izrade

Kratice:

3D	trodimenzionalan
ACO	optimizacija mravljeg roja (engl. <i>Ant Colony Optimization</i>)
ANN	umjetne neuronske mreže (engl. <i>Artificial Neural Network</i>)
BOM	troškovnik (engl. <i>Bill Of Materials</i>)
CNC	računalom podržano numeričko upravljanje (engl. <i>Computer Numerical Control</i>)
DES	simulacija diskretnih događaja (engl. <i>Discrete Event Simulation</i>)
DP	dinamičko programiranje (engl. <i>Dynamic Programming</i>)
EA	evolucijski algoritmi (engl. <i>Evolutionary Algorithms</i>)
EDD	najraniji rok isporuke (engl. <i>Earliest Due Date</i>)
engl.	engleski
ERP	planiranje resursa poduzeća (engl. <i>Enterprise Resource Planning</i>)
FCFS	prvi stigao, prvi poslužen (engl. <i>First Come First Served</i>)
FFS	fleksibilni linijski proizvodni sustav (engl. <i>Flexible Flow Shop</i>)
FIFO	prvi ušao, prvi izlazi (engl. <i>First In First Out</i>)
FMS	fleksibilni proizvodni sustav (engl. <i>Flexible Manufacturing System</i>)
FSMP	linijski proizvodni sustav s više strojeva (engl. <i>Flow Shop with Multiple Processors</i>)
FSPM	linijski proizvodni sustav s paralelnim strojevima (engl. <i>Flow Shop with Parallel Machines</i>)
GA	genetski algoritmi (engl. <i>Genetic Algorithms</i>)
GRASP	pohlepni nasumični postupak prilagodljivog pretraživanja (engl. <i>Greedy Randomized Adaptive Search Procedure</i>)
HFS	hibridni linijski proizvodni sustav (engl. <i>Hybrid Flow Shop</i>)
IP	cjelobrojno programiranje (engl. <i>Integer Programming</i>)
JLPS	jednopredmetni linijski proizvodni sustav
LOR	najmanje operacija preostaje (engl. <i>Least Operations Remanining</i>)
LP	linearno programiranje (engl. <i>Linear Programming</i>)
LPT	najdulje vrijeme izvođenja operacije (engl. <i>Longest Processing Time</i>)
LS	lokalno pretraživanje (engl. <i>Local Search</i>)

MFS	višestrojni linijski proizvodni sustav (engl. <i>Multiprocessor Flow Shop</i>)
MOR	najviše operacija preostaje (engl. <i>Most Operations Remaining</i>)
MRP	planiranje materijalnih potreba (engl. <i>Material Requirements Planning</i>)
MTTR	prosječno vrijeme za popravak (engl. <i>Mean Time To Repair</i>)
n.j.	novčana jedinica
PS	proizvodni sustav
RANDOM	slučajan odabir
RM	radno mjesto
SA	simulirano kaljenje (engl. <i>Simulated Annealing</i>)
SDST	pripremno-završno vrijeme ovisno o slijedu (engl. <i>Sequence-Dependent Setup Time</i>)
SIMSET	najkraće pripremno-završno vrijeme (engl. <i>Similar Setup Time</i>)
SPT	najkraće vrijeme izvođenja operacije (engl. <i>Shortest Processing Time</i>)
TS	tabu pretraživanje (engl. <i>Tabu Search</i>)
VLPS	višepredmetni linijski proizvodni sustav

POPIS SLIKA

Slika 1.1. Inženjerski trinom - potrebno je proizvesti dovoljno kvalitetan proizvod uz što manje troškove proizvodnje za predviđeni vremenski period	2
Slika 1.2. Broj objavljenih radova koji se bave problemom planiranja redoslijeda u proteklih deset godina.....	4
Slika 2.1. Osnovne kategorije planiranja proizvodnje: dugoročno planiranje, srednjoročno planiranje i kratkoročno planiranje	13
Slika 2.2. Dijagram toka informacija u proizvodnom sustavu (Pinedo, 2016.)	17
Slika 2.3. Odluke o planiranju rasporeda proizvodnje u proizvodnim poduzećima (Georgiadis i sur., 2019.).....	18
Slika 2.4. Shema višepredmetnoga linijskoga proizvodnog sustava (Jiang i Zhang, 2019.) ...	26
Slika 2.5. Sinonimi korišteni u literaturi za višepredmetni linijski ili protočni proizvodni sustav	27
Slika 3.1. Križanje u jednoj točki - zadnji dijelovi niza gena se zamijene u točki prekida.....	44
Slika 3.2. Križanje u tri točke - dijelovi niza gena iza točaka prekida se zamijene	45
Slika 3.3. Uniformno križanje - svaki gen se nasumično bira između roditelja.....	45
Slika 3.4. Inverzija dijela niza gena između pozicija 2 i 5	45
Slika 3.5. Mutacija zamjenom - zamjenjuju se pozicije 3 i 5.....	46
Slika 3.6. Mutacija umetanjem gena s pozicije 5 na poziciju 3, a ostali geni se pomiču za jedno mjesto udesno	46
Slika 3.7. Mutacija permutiranjem dijela niza gena između pozicija 3 i 6	46
Slika 3.8. Mutacija dodjelom - genu na poziciji 4 dodijeljena je nova vrijednost	46

Slika 3.9. Osnovni koncept simulacijskog procesa (Božikov, 2007.).....	52
Slika 4.1. Utjecaj veličine jedinične serije na vrijeme trajanja proizvodnje	68
Slika 4.2. Utjecaj redoslijeda ulaska različitih jediničnih serija na vrijeme trajanja proizvodnje	70
Slika 5.1. Shema simulacijskog modela (Carson i Maria, 1997.)	78
Slika 5.2. Simulacijski okvir za određivanje optimalnoga vremenskog iskorištenja.....	81
Slika 5.3. Primjer izrađenog simulacijskog modela VLPS-a	83
Slika 5.4. GA parametri optimizacije.....	87
Slika 5.5. Umjetni kromosom za veličinu jedinične serije i vjerojatnost ulaska jedinične serije za svaku vrstu proizvoda	88
Slika 5.6. Stohastička metoda odabira - odabir kotačem ruleta (Newcastle University, 2021.)	89
Slika 5.7. Križanje u dvije točke - zamjenjuju se geni između pozicija 3 i 5	90
Slika 5.8. a) prvi potomak - mutacija na drugom i petom genu; b) drugi potomak - bez mutacije	90
Slika 5.9. Odabir vrijednosti parametara genetskih operatora	90
Slika 5.10. Selekcija jedinki za reprodukciju i odabir jedinki za novu populaciju	91
Slika 6.1. Simulacijski model VLPS-a izrađen u programskom paketu Tecnomatix Plant Simulation	98
Slika 6.2. Simulacijski model VLPS-a - prva faza proizvodnje.....	98
Slika 6.3. Simulacijski model VLPS-a - druga faza proizvodnje.....	98
Slika 6.4. Simulacijski model VLPS-a - treća faza proizvodnje	99
Slika 6.5. Simulacijski model VLPS-a - četvrta faza proizvodnje.....	99
Slika 6.6. Simulacijski model VLPS-a - peta faza proizvodnje	99

Slika 6.7. Dijaloški okvir Machine - uneseni raspon pripremno-završnog vremena	100
Slika 6.8. Metoda OnEntrance - služi za postavljanje vremena operacija te uvjetuje zamjenu alata uslijed istrošenja oštice.....	101
Slika 6.9. Metoda OnSetup - služi za izračun ukupnog pripremno-završnog vremena	101
Slika 6.10. Tablica ProcTime - redoslijed i vremena operacija za proizvode D, E i F	102
Slika 6.11. Kalendar radnih smjena	103
Slika 6.12. Validacija simulacijskog modela - prva provjera	105
Slika 6.13. Validacija simulacijskog modela - druga provjera (prema podacima iz realnog okruženja).....	106
Slika 6.14. Rubni uvjeti varijabli odlučivanja - veličina jediničnih serija i vjerojatnost ulaska jediničnih serija proizvoda u sustav	108
Slika 6.15. Slučaj 1 - funkcija cilja	109
Slika 6.16. Slučaj 1 - rezultati optimizacije	109
Slika 6.17. Slučaj 1 - evolucijski dijagram.....	110
Slika 6.18. Slučaj 1 - rezultati simulacije proizvodnog procesa za dobivene optimalne vrijednosti veličine i vjerojatnosti ulaska jediničnih serija	110
Slika 6.19. Slučaj 1 - gantogram dodjele jediničnih serija proizvoda D, E i F proizvodnim resursima u pojedinim fazama proizvodnje	112
Slika 6.20. Slučaj 2 - funkcija cilja	114
Slika 6.21. Slučaj 2 - rezultati optimizacije	115
Slika 6.22. Slučaj 2 - evolucijski dijagram.....	116
Slika 6.23. Slučaj 2 - rezultati simulacije proizvodnog procesa za dobivene optimalne vrijednosti veličine i vjerojatnosti ulaska jediničnih serija	116

Slika 6.24. Slučaj 2 - gantogram dodjele jediničnih serija proizvoda D, E i F proizvodnim resursima u pojedinim fazama proizvodnje	118
Slika 6.25. Slučaj 3 - funkcija cilja	120
Slika 6.26. Slučaj 3 - rezultati optimizacije	120
Slika 6.27. Slučaj 3 - evolucijski dijagram.....	121
Slika 6.28. Slučaj 3 - rezultati simulacije proizvodnog procesa za dobivene optimalne vrijednosti veličine i vjerojatnosti ulaska jediničnih serija	121
Slika 6.29. Slučaj 3 - gantogram dodjele jediničnih serija proizvoda D, E i F proizvodnim resursima u pojedinim fazama proizvodnje	123

POPIS TABLICA

Tablica 3.1. Lista pravila otpreme.....	37
Tablica 3.2. Poveznica između pojmova iz teorije evolucije i genetskih algoritama	41
Tablica 5.1. Simulacijski programski paketi s korištenim optimizacijskim alatima.....	79
Tablica 6.1. Ulazni podaci - proizvodni program	94
Tablica 6.2. Ulazni podaci - redoslijed i vrijeme odvijanja operacija.....	94
Tablica 6.3. Ulazni podaci - Proizvodni kapaciteti	95
Tablica 6.4. Ulazni podaci - Alati	95
Tablica 6.5. Ulazni podaci - Transport.....	96
Tablica 6.6. Ulazni podaci - Proizvodi.....	96

ŽIVOTOPIS

David Ištoković rođen je 14. svibnja 1989. godine u Đakovu. U Zagrebu je pohađao i završio Osnovnu školu Vjenceslav Novak te XV. gimnaziju. Preddiplomski sveučilišni studij strojarstva upisuje na Tehničkom fakultetu Sveučilišta u Rijeci koji završava 2014. godine obranom završnog rada *Odabir materijala za balističke prsluke* pod vodstvom mentorice prof. dr. sc. Lorete Pomenić te stječe akademski naziv sveučilišnog prvostupnika (baccalaureus) inženjera strojarstva. Iste godine upisuje Diplomski sveučilišni studij strojarstva također na Tehničkom fakultetu Sveučilišta u Rijeci. Obranom diplomskog rada *Idejni projekt proizvodnog sustava strojne obrade* pod mentorstvom prof. dr. sc. Milana Ikonića, 2016. godine, stječe akademski naziv magistar inženjer strojarstva.

Početkom 2017. godine zapošljava se na Tehničkom fakultetu Sveučilišta u Rijeci na Zavodu za industrijsko inženjerstvo i management na radno mjesto asistenta s punim radnim vremenom na Katedri za projektiranje procesa. Za mentora studija mu je dodijeljen prof. dr. sc. Mladen Perinić. U nastavi sudjeluje kroz izvođenje auditornih i laboratorijskih vježbi iz kolegija Projektiranje tehnoloških procesa, Računalna simulacija proizvodnih procesa i CAD/CAPP/CAM na diplomskom sveučilišnom studiju strojarstva, iz kolegija Tehnološki procesi na preddiplomskom sveučilišnom studiju strojarstva, te iz kolegija Tehnološki procesi na stručnom studiju strojarstva. U akademskoj godini 2017.-2018., na Katedri za organizaciju i operacijski management izvodi auditorne vježbe iz kolegija Organizacija i ekonomika poslovnih sustava na preddiplomskom sveučilišnom studiju strojarstva, brodogradnje, elektrotehnike i računarstva, kao i auditorne vježbe iz kolegija Menadžment i organizacijski razvoj na diplomskom sveučilišnom studiju strojarstva. Od akademske godine 2019.-2020., na Katedri za proizvodnu opremu i robotiku izvodi auditorne i laboratorijske vježbe iz kolegija Fleksibilni i inteligentni sustavi na diplomskom studiju strojarstva.

U listopadu 2018. godine upisuje Poslijediplomski doktorski studij iz tehničkih znanosti, znanstveno polje strojarstvo, znanstvena grana proizvodno strojarstvo, na Tehničkom fakultetu Sveučilišta u Rijeci, te od tada sudjeluje u znanstveno-istraživačkom radu. Autor je dva izvorna znanstveno-istraživačka rada u inozemnim znanstvenim časopisima indeksiranim u bazama

Current Contents, od toga oba rada kao prvi autor. Isto tako, autor je još nekoliko znanstvenih i stručnih radova u domaćim ili inozemnim znanstvenim i stručnim časopisima. Dva rada je izlagao na međunarodnim skupovima. U svrhu znanstvenog usavršavanja, boravio je tri mjeseca na Strojarskom fakultetu u Slavonskom Brodu na Katedri za pripremu i upravljanje proizvodnjom. Sudjeluje na dva znanstveno-istraživačka projekta, kao doktorand na projektu *Napredne metode simulacije operativne pripreme planiranja proizvodnje* i kao suradnik na projektu *Primjena tehnologija inkrementalnog oblikovanja u individualnoj proizvodnji izradaka iz naprednih polimernih materijala*. Također, sudjelovao je kao član projektnog tima na stručnom projektu *Analiza tehnoloških procesa i aktivnosti te izrada prijedloga prometnog rješenja lučkog područja Bršica*, za državnu lučku upravu Rijeka.

Aktivno se služi engleskim jezikom. Tijekom studiranja stručno se usavršavao polaganjem svih ispita te stjecanjem certifikata SolidWorks Professional (CSWP). Oženjen je i otac trogodišnjeg sina Emanuela.

POPIS OBJAVLJENIH RADOVA

1. Ištoković, D., Perinić, M., Vlatković, M., Brezočnik, M. (2020). Minimizing total production cost in a hybrid flow shop: a simulation-optimization approach, *International Journal of Simulation Modelling*, Vol. 19, No. 4, 559-570, doi: 10.2507/IJSIMM19-4-525
2. Ištoković, D., Perinić, M., Jurković, Z. (2019). Minimizing the makespan in the flowshop with sequence-dependent setup times: simulation approach, *Proceedings of 9th International Conference "Mechanical Technologies and Structural Materials" MTSM 2019*, Split, 77-82
3. Ištoković, D., Perinić, M., Doboviček, S., Bazina, T. (2019). Simulation framework for determining the order and size of the product batches in the flow shop: A case study, *Advances in Production Engineering & Management*, Vol. 14, No. 2, 166-176, doi: 10.14743/apem2019.2.319
4. Salopek, G., Dunder, M., Perinić, M., Ištoković, D., Jurković, Z., Marković, M. (2018). Advantages of additive manufacturing in production of gears for planetary reducers, *Proceedings of 8th International Conference "Mechanical Technologies and Structural Materials" MTSM 2018*, Split, 167-172
5. Nakić, I., Ištoković, D., Perinić, M., Cukor, G. (2017). Implementation of additive technology in medicine, *Proceedings of 7th International Conference "Mechanical Technologies and Structural Materials" MTSM 2017*, Split, 89-97