Primjena simulacijskog modeliranja u analizi procesa prijema robe u skladište

Kukovačec, Leon

Undergraduate thesis / Završni rad

2021

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Transport and Traffic Sciences / Sveučilište u Zagrebu, Fakultet prometnih znanosti**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:119:060926

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**



Repository / Repozitorij:

Faculty of Transport and Traffic Sciences - Institutional Repository







SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI
ODBOR ZA ZAVRŠNI RAD

Zagreb, 4. svibnja 2021.

Zavod: **Zavod za transportnu logistiku**
Predmet: **Osnove simulacija u prometu i logistici**

ZAVRŠNI ZADATAK br. 6180

Pristupnik: **Leon Kukovačec (0135251698)**
Studij: Inteligentni transportni sustavi i logistika
Smjer: Logistika

Zadatak: **Primjena simulacijskog modeliranja u analizi procesa prijema robe u skladište**

Opis zadatka:

Prikazati prednosti i nedostatke simulacijskih metoda općenito, te mogućnost primjene simulacijskih modela u svrhu analize logističkih procesa. Izraditi simulacijski model logističkog procesa prijema robe u skladište i provesti simulacijski eksperiment sa stvarnim ili fiktivnim ulaznim podacima. Prikazati i objasniti rezultate simulacijskog eksperimenta.

Mentor:

izv. prof. dr. sc. Ratko Stanković

Predsjednik povjerenstva za završni ispit:

SVEUČILIŠTE U ZAGREBU

FAKULTET PROMETNIH ZNANOSTI

Leon Kukovačec

PRIMJENA SIMULACIJSKOG MODELIRANJA U ANALIZI PROCESA PRIJEMA ROBE U SKLADIŠTE

ZAVRŠNI RAD

ZAGREB 2021

SVEUČILIŠTE U ZAGREBU

FAKULTET PROMETNIH ZNANOSTI

ZAVRŠNI RAD

PRIMJENA SIMULACIJSKOG MODELIRANJA U ANALIZI PROCESA PRIJEMA ROBE U SKLADIŠTE

APPLYING SIMULATION MODELING IN ANALYSIS OF THE WAREHOUSE RECEIVING PROCESS

Mentor: izv. Prof. Dr. Sc. Ratko Stanković

Student: Leon Kukovačec

JMBAG:0135251698

Zagreb, rujan 2021

Sažetak

Simulacijsko modeliranje se koristi kako bi se logistički proces provjerio te poboljšao. Svaki skladišni proces treba imati unaprijed napravljen simulacijski eksperiment kako bi se provjerilo da li ima mjesta za poboljšanje bilo kojeg dijela procesa. U fokusu ovog rada je opisivanje simulacijskih metoda, prednosti i nedostataka simulacijskih metoda, te opisivanje procesa prijema robe, kao i simulacijski eksperiment procesa prijema robe.

KLJUČNE RIJEČI: simulacijsko modeliranje, simulacijski eksperiment, skladišni proces, prijem robe

SUMMARY

Simulation modeling is used to check and improve logistics process. Each storage process should have a pre-made simulation experiment to check if there is room to improve any part of the process. The focus of this paper is to describe the simulation methods, advantages and disadvantages of simulation methods, and to describe the process of receiving goods, as well as a simulation experiment of the process of receiving goods.

KEY WORDS: simulation modeling, simulation experiment, storage process, receiving goods

Sadržaj

1.Uvod 1
2. Simulacijske metode i modeli 2
2.1 Metode modeliranja 3
2.1.1. Analitičko modeliranje 3
2.1.2. Numeričke metode 3
2.1.3. Simulacijski modeli 3
2.2. Prednosti i nedostaci simulacije 3
2.3. Podjele simulacijskih modela 4
2.3.1. Deterministički i stohastički modeli 4
2.3.2. Diskretni i kontinuirani modeli 5
2.4. Tipovi simulacijskih modela 6
2.4.1. Monte Carlo simulacija 7
2.4.2. Kontinuirana simulacija 8
2.4.3. Simulacija diskretnih događaja 10
2.4.4. Kombinirana diskretno-kontinuirana simulacija 10
3. Simulacijski programski alati 12
3.1 FlexSim 12
3.2.Arena 13
3.3.Extendsim 14
4.Simulacijski model procesa prijema robe u skladište 16
5.Planiranje i izvođenje simulacijskog eksperimenta 17
6.Prikaz rezultata simulacijskog eksperimenta 25
7.Zaključak 28
Literatura 29
Popis slika 30
Popis tablica 31

1.Uvod

Primjena simulacijskih modela je veoma široka, ne samo u logistici nego i u jako puno zanimanja. Omogućuje da se pojedini procesi analiziraju prije nego li se zapravo implementiraju u stvarnom životu. To može biti jako korisno, zato jer može pokazati da li se negdje u procesu prave greške, ili se nešto da još poboljšat. Ovaj rad se sastoji od sedam cjelina:

1. Uvod
2. Simulacijske metode i modeli
3. Simulacijski programski alati
4. Simulacijski model procesa prijema robe u skladište
5. Planiranje i izvođenje simulacijskog eksperimenta
6. Prikaz rezultata simulacijskog eksperimenta
7. Zaključak

U drugoj cjelini opisane su simulacijske metode i modeli, prednosti i nedostaci simulacije, te također prikazati podjele simulacijskih metoda. U trećoj cjelini opisani su programski alati preko kojih se izrađuju simulacijski modeli. U četvrtoj cjelini je prikazan simulacijski model procesa prijema robe u skladište te je opisan proces prijema robe u skladište. Peta cjelina se sastoji od prikazivanja parametara simulacijskog eksperimenta, te su opisani svi dijelovi simulacijskog modela. U šestoj cjelini su prikazani rezultati simulacijskog eksperimenta iz pete cjeline. Zadnja cjelina se sastoji od zaključka u kojem je sažeta misao cijelog završnog rada.

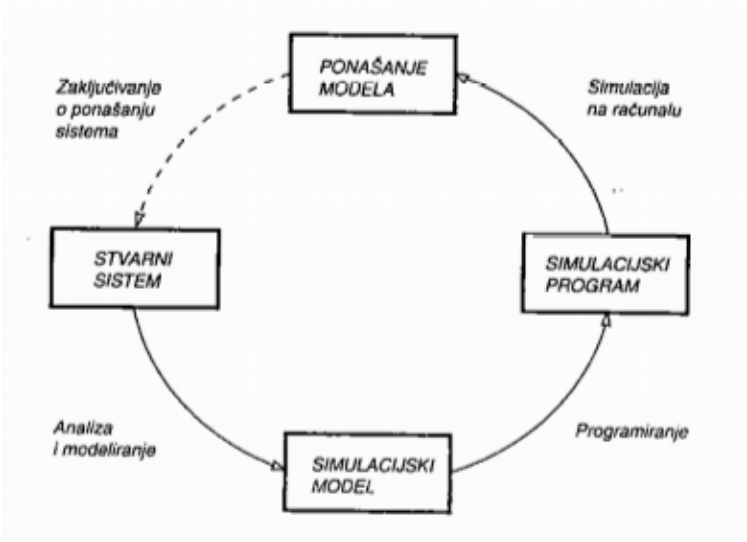
2. Simulacijske metode i modeli

Simulacijski modeli su modeli dinamičkih sustava. Dinamički sustavi su sustavi koji se mijenjaju u vremenu. Simulacijski modeli moraju omogućiti efikasno izvođenje pomaka vremena, te je bitno omogućavanje istovremenog odvijanja aktivnosti kao i opisivanje procesa koji konkuriraju za iste resurse. Ti su zahtjevi problem za modeliranje, te su zbog toga simulacijski modeli razvijeni u posebnu kategoriju modela. Također su razvijeni i alati za konceptualno modeliranje i specifični programski jezici kao adekvatna sredstva za posebne zahtjeve simulacijskog modeliranja [1].

U primjeni simulacijskog modeliranja ne može se dobiti rješenje u analitičkom obliku, već se rješenje problema dobiva eksperimentiranjem modelom sustava. Simulacijski eksperimenti daju kao rezultat skup točaka, tj. vrijednosti zavisnih varijabli za pojedine vrijednosti nezavisnih varijabli. Pri tome planiranje i analiza simulacijskih eksperimenata zahtjevaju statistički pristup [1].

Moderno modeliranje je nezamislivo bez računala. Uz različite metode i programske alate računarske znanosti omogućuju dobar ambijent za stvaranje složenih modela i efikasan rad s njima. Računala se u modeliranju koriste u dvije svrhe: u razvoju modela i u izvođenju proračuna na temelju stvorenog modela [1].

Osnovne komponente simulacijskog modeliranja i njihove relacije prikazane su na slici 1.



Slika 1: Sustavi, modeli, simulacija

Izvor: Čerić, V.: Simulacijsko modeliranje, Školska knjiga, Zagreb, 1993

2.1 Metode modeliranja

Prema rastućoj složenosti sustava, metode modeliranja i rješavanja problema jesu:

1. Analitičko modeliranje
2. Numeričke metode
3. Simulacijski modeli [1]

2.1.1. Analitičko modeliranje

Modeli su u analitičkom obliku, pa su i rješenja u analitičkom obliku. To su modeli problema koji se svode na matematički tretman pomoću metoda algebre, matematičke analize, teorije vjerojatnosti. Primjer takvih problema su jednostavni problemi njihala i repova čekanja [1].

2.1.2. Numeričke metode

Modeli su u analitičkom obliku, ali zbog nemogučnosti nalaska analitičkog rješenja, se rješavaju numeričkim postupcima. Primjer problema koji se rješavaju numeričkim metodama su složeniji problemi repova čekanja, difuzije, vremenske prognoze itd [1].

2.1.3. Simulacijski modeli

Zbog nemogućnosti prikaza složenih dinamičkih sustava u analitičkom obliku, modeli su zadani u proceduralnom obliku kojim se prikazuje način rada sustava. Problem se rješava numerički, provođenjem eksperimenata modelom koji oponašaju razvoj sustava u vremenu. Primjer sustava koji se modelira ili analizira simulacijskim modeliranjem jesu diskretni sustavi (npr. proizvodni procesi, transportni sustavi). Simulacijski modeli značajno proširuju klasu problema dostupnih za rješavanje. Cijena toga je povećanje složenosti izgradnje modela i rješavanja problema [1].

2.2. Prednosti i nedostaci simulacije

Prednosti simulacijskog modeliranja su:

1. Moguće je opisati i rješavati složene dinamičke probleme sa slučajnim varijablama koji su nedostupni matematičkom modeliranju
2. Moguće je riješiti raznovrsne probleme (oblikovanje, analizu rada, itd.)
3. Uvjeti eksperimentiranja su pod potpunom kontrolom, za razliku od eksperimenata sa stvarnim sustavom gdje nije moguće utjecati na npr. brzinu rada šaltera
4. Vrednovanje i analiza logike i dinamike rada sustava veoma su olakšani animacijom rada modela [1]

Nedostaci simulacijskog modeliranja su:

1. Razvoj modela je i dug i skup
2. Zbog statističkog karaktera simulacije potrebno je izvođenje većeg broja simulacijskih eksperimenata kako bi se dobio odgovarajući uzorak rezultata simulacije, a već i pojedinačno izvođenje eksperimenata može zahtjevati dosta vremena i memorije računala
3. Ne dobivaju se zavisnosti izlaznih varijabli o ulaznim varijablama modela ni optimalna rješenja
4. Za ispravno korištenje simulacijskog modeliranja potrebno je poznavanje više različitih metoda i alata
5. Vrednovanje modela je dosta složeno i zahtjeva dodatne eksperimente [1]

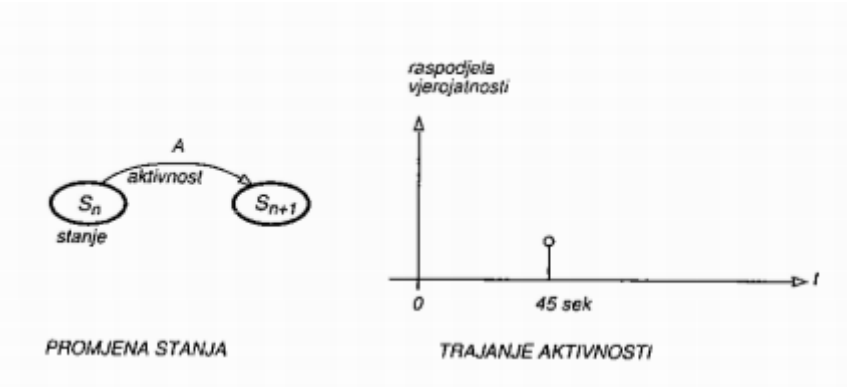
2.3. Podjele simulacijskih modela

Simulacijske modele dijelimo na dva osnovna tipa, jedan prema vrsti varijabli u modelu, a drugi prema načinu po kojem se stanje modela mijenja u vremenu [1].

2.3.1. Deterministički i stohastički modeli

Deterministički modeli su modeli čije je ponašanje potpuno predvidljivo, novo stanje sustava koji je modeliran potpuno je određen prethodnim stanjem [1].

Na slici 2. je prikazan deterministički model u kojem se stanje sustava S_n promjenilo pod utjecajem aktivnosti A u stanje S_{n+1}. Prikazana je i aktivnost A s determinističkim trajanjem od 42 sekunde.

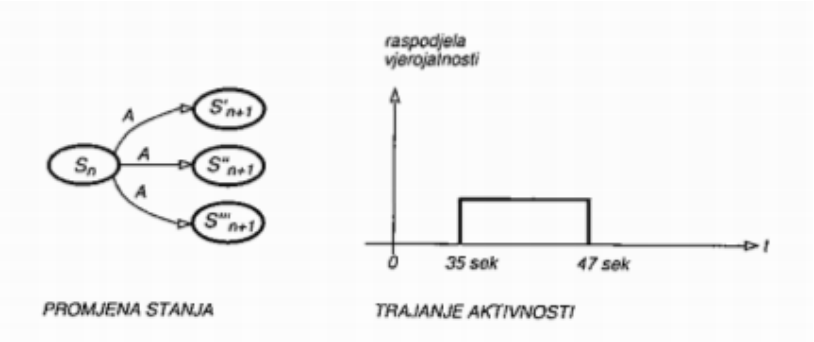


Slika 2: Deterministički model

Izvor: Čerić, V.: Simulacijsko modeliranje, Školska knjiga, Zagreb, 1993

Stohastički modeli su oni čije se ponašanje ne može unaprijed predvidjeti, ali se mogu odredit vjerojatnosti promjena stanja sustava. Stohastičke modele karakterizira slučajno ponašanje, odnosno postojanje slučajnih varijabli u sistemu [1].

Na slici 3. je prikazan stohastički model u kojem se stanje sustava S_n može promijeniti u jedno od stanja: S_{n+1}', S_{n+1}'', S_{n+1}''' pod utjecajem aktivnosti A. Tako neki stroj može nakon izvođenja operacije ostati ili u ispravnom stanju ili se pokvariti, pri čemu svako od tih stanja ima neku vjerojatnost.

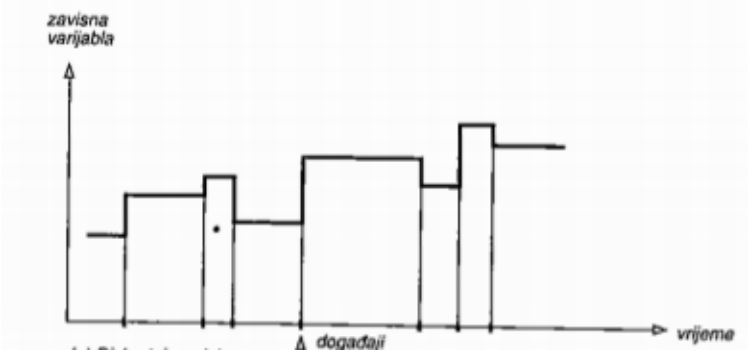


Slika 3: Stohastički model

Izvor: Čerić, V.: Simulacijsko modeliranje, Školska knjiga, Zagreb, 1993

2.3.2. Diskretni i kontinuirani modeli

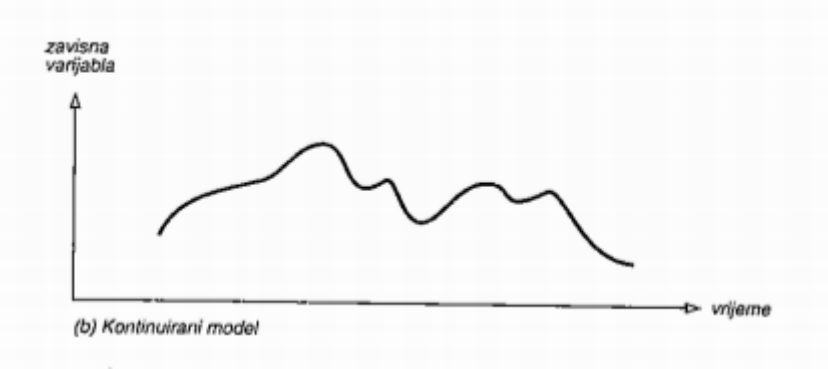
U diskretnim modelima se stanje sistema mijenja u samo nekim vremenskim točkama. Takve promjene se nazivaju događaji [1]. Diskretna promjena stanja prikazana je na slici 4. Tako model prodavaonice sa samoposluživanjem može zadržati opisuju broj ljudi u repovima pred blagajnama. Broj se može mijenjati samo u času početka posluživanja na blagajni i u času dolaska ljudi u rep [1].



Slika 4: Diskretni model

Izvor: Čerić, V.: Simulacijsko modeliranje, Školska knjiga, Zagreb, 1993

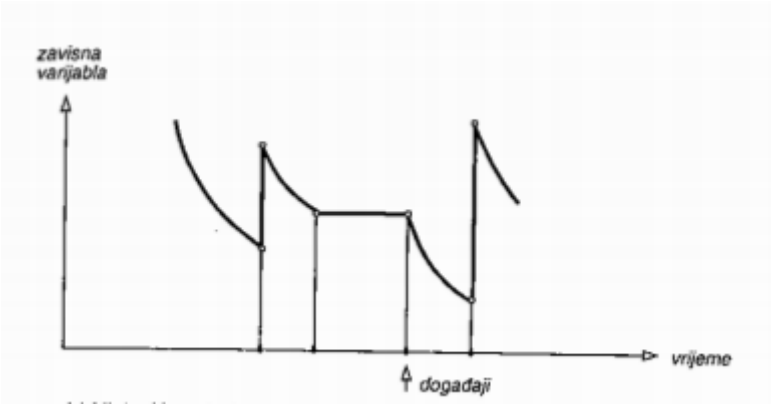
Kontinuirani modeli varijable stanja mijenjaju kontinuirano u vremenu kao što je prikazano na slici 5. Primjer kontinuirane promjene je let aviona čiji se položaj i brzina mijenjaju kontinuirano u vremenu. Na digitalnim računalima se ne mogu izvoditi kontinuirane promjene veličina, već se one aproksimiraju brojevima od konačno mnogo znamenki. Zbog ograničenja u ukupnom vremenu izvođenja simulacije mora se kontinuirani tok vremena zamjeniti pomakom vremena u malim odsječcima [1].



Slika 5: Kontinuirani model

Izvor: Čerić, V.: Simulacijsko modeliranje, Školska knjiga, Zagreb, 1993

Mogući modeli su također i miješano kontinuirano-diskretni modeli koji sadrže i kontinuirane i diskretne varijable [1]. Promjena stanja takvog modela prikazana je na slici 6.



Slika 6: Kontinuirano-diskretni model

Izvor: Čerić, V.: Simulacijsko modeliranje, Školska knjiga, Zagreb, 1993

2.4. Tipovi simulacijskih modela

Prikazane podjele simulacijskih modela dovele su do formiranja četiriju osnovnih tipova simulacijskih modela, koji se razlikuju i sa pristupnim modeliranjem i sa tipovima problema

koji se njima rješavaju, kao i tehnikama modeliranja i simulacijama koje su za njih razvijene [1].

Ta 4 osnova tipa simulacijskih modela su:

- Monte carlo simulacija
- Kontinuirana simulacija
- Simulacija diskretnih događaja
- Miješana kontinuirano-diskretna simulacija [1]

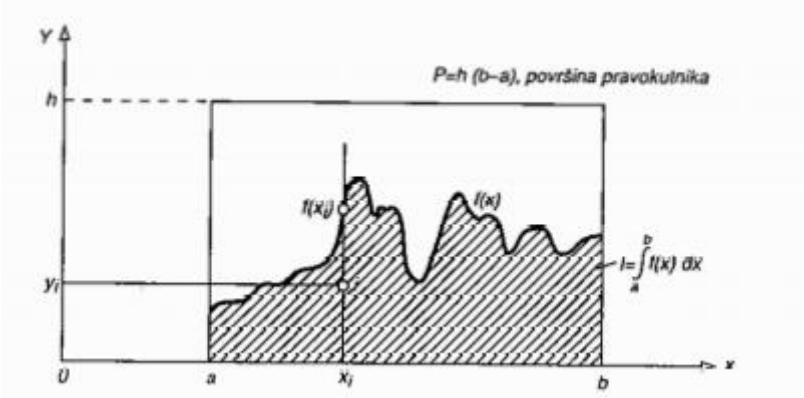
2.4.1. Monte Carlo simulacija

Monte Carlo simulacija (statistička simulacija) povezana je sa slučajnim fenomenima. Ovo je jedna od prvih primjena programiranja računala. Metoda je razvijena u toku drugog svjetskog rata u Los Alamosu za rješavanje složenih problema vezanih za proizvodnju atomske bombe, poput proračuna o raspršenju neurona na atomskoj jezgri. Razlikujemo ove tipove primjene Monte Carlo simulacije:

1. Deterministički problemi koje je teško ili skupo rješavati

Tipičan primjer je računanje vrijednosti određenih integrala koji se ne mogu riješiti analitički, čija je podintegralna funkcija takva da se ne može naći rješenje u obliku matematičkog izraza.

Monte Carlo simulacija pristupa proračunu integrala tako da se generira niz slučajnih točaka jedne vjerojatnosti unutar pravokutnika te da se za svaku točku ispita da li je pala unutar površine koja odgovara vrijednosti integrala. Točke se generiraju tako da se generira dvojka vrijednosti y_i uniformnim generatorom za interval (0, h). Zatim se ispita da li je točka generirana unutar površine koja odgovara integralu [1]. Na slici 7. prikazan je primjer računanja jednostrukog integrala [1].



Slika 7: Računanje određenog integrala, Monte Carlo simulacija

Izvor: Čerić, V.: Simulacijsko modeliranje, Školska knjiga, Zagreb, 1993

2. Složeni fenomeni koji nisu dovoljno poznati

Druga klasa problema koji se rješavaju Monte Carlo simulacijom su fenomeni koji nisu dovoljno poznati da bi se mogli precizno opisati. Umjesto poznavanja načina međudjelovanja elemenata poznate su samo vjerojatnosti ishoda međudjelovanja, koje se u Monte Carlo simulaciji koriste za izvođenje niza eksperimenata što daju uzorke mogućih stanja zavisnih varijabli. Statističkom analizom takvih uzoraka dobiva se razdioba vjerojatnosti zavisnih varijabli od interesa. Ovim se pristupom najčešće analiziraju društveni ili ekonomski fenomeni poput rasta populacija, ekonomskih predviđanja ili analize rizika odlučivanja [1].

3. Statistički problemi koji nemaju analitičkog rješenja

Statistički problemi bez analitičkog rješenja jedna su od širokih klasa problema kod koje se koristi Monte Carlo simulacija. Njima pripadaju procjene kritičkih vrijednosti, snage testiranja novih hipoteza. U rješavanju problema također se koristi generiranje slučajnih brojeva i varijabli [1].

Kod usporedbe različitih metoda regresije Monte Carlo simulacija služi za generiranje ulaznih podataka, koji se zatim analiziraju različitim metodama te daju procjene parametara regresije tih podataka. Budući da su ulazni podaci generirani s unaprijed određenim parametrima, moguće je usporediti kvalitetu različitih metoda regresije po točnosti procjena parametra koje one daju s poznatim parametrima sa kojima su podaci generirani [1].

2.4.2. Kontinuirana simulacija

Kontinuirana simulacija koristi se za dinamičke probleme kod kojih se varijable stanja mijenjaju kontinuirano u vremenu. Dvije klase problema se riješavaju ovom metodom:

U prvoj klasi su razmjerno jednostavni problemi koji su opisani vrlo detaljno kod kojih su promjene „glatke“ i prirodno se opisuju diferencijalnim jednađbama. Tipično su problemi u području fizike, biologije i inžinjerstva [1].

U drugoj klasi su problemi što nastaju opisom veoma složenih sustava u agregiranom obliku, u kojem niz elemenata sustava reducira na što manji broj komponenti te u kojima se promjene u sustav aproksimiraju konstantnim brzinama promjene. To su najčešće problemi iz područja ekonomije i društvenih znanosti [1].

Tri su osnovna tipa kontinuiranih simulacijskih modela:

1. Sustavi običnih diferencijalnih jednadžbi

To su jednađbe sa jednom nezavisnom varijablom (x) po kojoj se deriviraju zavisne varijable (y), čija je brzina promjene (dy/dx) opisana u odnosu prema nezavisnoj varijabli. Rješavanje problema kontinuiranom simulacijom izvodi se pomakom vremena za zadani vremenski interval, i rješavanja statičkog sustava jednađbi u točkama pomaka vremena [1].

2. Sustavi parcijalnih diferencijalnih jednadžbi

One sadrže više od jedne nezavisne varijable (x_j) po kojima se deriviraju zavisne varijable. Tipični primjeri problema koji se mogu opisati parcijalnim diferencijalnim jednadžbama su problemi aerodinamike, hidrodinamike i temperature u tri prostorne dimenzije i vremenu [1].

Sustavi parcijalnih diferencijalnih jednadžbi zovu se još i sustavi s distribuiranim parametrima, za razliku od sustava običnih diferencijalnih i diferencijskih jednadžbi koje se zovu sistemi s grupiranim parametrima [1].

3. Sustavna dinamika

Sustavna je dinamika simulacija sustava s povratnom vezom, sustavi u kojima stoji veza između izlaza i ulaza sustava. Povratna veza može biti pozitivna, kada se pojačava rad sustava, ili negativna, kada se rad sustava stabilizira ili zagušuje. Primjer neke negativne povratne veze je sustav za grijanje prostorija upravljan termostatom. Kada temperatura u sobi naraste preko neke granice, tada će termostat isključiti grijanje, a kada padne ispod neke granice, tada će ga ponovno uključiti. Primjer pozitivne povratne veze je porast broja stanovnika zbog rađanja. Kada ne bi bilo smrtnosti, broj stanovnika bi brzo rastao (bez uzimanja drugih ograničenja u obzir) [1].

Modeli s povratnom vezom koriste se za modeliranja inžinjerskih sustava te bioloških, ekonomskih i društvenih fenomena. Sustavna dinamika prikazuje sustave kao povezane

upravljačke petlje. Događaji su agregirani, a posljedica toga je da se mogu opisivati kao kontinuirani tokovi opisani diferencijalnim jednadžbama. Novo stanje sustava u sljedečem satu računa se na temelju promjena koje nastupaju u stanu iz prethodnog vremenskog sata, odnosno iz više prethodnih satova [1].

Jedan od najpoznatijih primjera primjene sustavne dinamike bila je prva studija granica rasta na Zemlji objavljena u knjizi Granice rasta. Model rasta obuhvatio je i povezao utjecaje osnovnih faktora važnih za život na zemlji: porast broja stanovnika, proizvodnju hrane, crpljenje zaliha ruda, potrošnju energije, zagađivanje, industrijski i uslužni kapital itd [1].

2.4.3. Simulacija diskretnih događaja

Simulacija diskretnih događaja ima mjesto među veoma detaljnim modelima kontinuiranih simulacija jednostavnih sustava i jako agregiranim modelima sustavne dinamike složenih sustava. Ta metoda omogućuje kombinaciju opisa detalja sustava i složenih međudjelovanja u njemu [1].

Simulacija diskretnih događaja uključuje modele koji su strukturirane kolekcije objekata. U aktivnostvima sustava međudjelovanje objekata uzrokuje promjene stanja sustava. Te promjene stanja (koje se zovu događaji) dešavaju se u diskretnim vremenskim trenucima. Ovom se metodom najčešće opisuju sustavi s repovima, oni sustavi u kojima dinamički objekti sustava traže posluživanje od ograničene kolekcije resursa (statičkih objekata). Posljedica ograničenja raspoložive količine resursa je stvaranje repova čekanja pod resursima [1].

Primjeri u kojima se primjenjuje simulacija diskretnih događaja mogu da budu modeli prodavaonica sa samoposluživanjem, aerodromskih zgrada, računalnih mreža, transportnih sustava i proizvodnih procesa [1].

2.4.4. Kombinirana diskretno-kontinuirana simulacija

Za neke vrste sustava ni kontinuirana simulacija ni simulacija diskretnih događaja ne mogu u potpunosti opisati način rada sustava. To su sustavi koji sadrže procese koji teku kontinuirano i događaje koji dovode do diskontinuiteta u razvoju sustava. Da bi se takvi sustavi modelirali i simulirali razvijena je kombinirana simulacija koja omogućuje integriranje kontinuiranih i diskretnih elemenata sustava. Veza između diskretnih i kontinuiranih pristupa postiže se dvama tipovima događaja [1].

Vremenski događaji su događaji koje planira upravljanje događajima, kakvo postoji i u simulaciji diskretnih događaja. Oni mogu trenutačno promjeniti stanje kontinuirane varijable. Događaji stanja su događaji koje aktivira upravljanje pomakom malih vremenskih intervala karakterističnih za kontinuirane simulacije. Ti se događaji mogu aktivirati kada kontinuirane varijable zadovolje neke uvjete (npr. kada vrijednost kontinuirane varijable prijeđe neki granični nivo) [1].

Diskretne i kontinuirane varijable mogu međudjelovati na nekoliko načina:

1. Diskretni događaj može aktivirati promjenu stanja kontinuirane varijable. Na primjer posipanje nekog područja sredstvima protiv komaraca smanjuje populaciju komaraca praktično trenutačno [1].
2. Diskretni događaj je u mogućnosti uzrokovati promjenu načina razvoja kontinuirane varijable. Primjer toga može biti zagađenje ekosustava nekim sredstvom koje može promjeniti relacije među populacijama različitih vrsta [1].
3. Ako vrijednost kontinuirane varijable prijeđe neki prag, to može uzrokovati dešavanje ili planiranje diskretnih događaja. Kada u kemijskom procesu koncentracija neke komponente padne ispod nekog nivoa kemijski proces završava i pokreće se proces čišćenja i održavanja postrojenja [1].

3. Simulacijski programski alati

Za simulacije logističkih procesa postoje programi u kojima određujemo parametre, te unosimo određene podatke pomoću kojih oni simuliraju rezultate ovisno o određenim parametrima i unešenim podacima. S obzirom da je to simulacija, pokretanjem dvije simulacije s istim parametrima ne mora značiti da će biti dobiveni isti rezultati.

Neki od najpopularnijih programskih alata koji se koriste za simulacije u logistici su:

- FlexSim
- Arena
- ExtendSim

3.1 FlexSim

Flexsim je najnapredniji program za simulacijsko modeliranje u kojem se koristi 3D modeliranje te se može koristiti za modeliranje i poboljšanje postojećih ili novih sustava. Neke od mogućnosti koje pruža su:

3D simulacije – Flexsim dolazi sa svim dokazanim prednostima simulacije diskretnih događaja, ali sa dodatnim bonusom visoko realistične sveobuhvatne 3D grafike. Flexsim modeli pomažu oponašati izgled i dojam stvarnog sustava, pa je lakše vidjeti i razumjet što se događa [2].

Izgled modela – olakšava što je više moguće ponavljanje izgleda vašeg sustava, a istovremeno zadržava detalje potrebne za točnu analizu. Dovoljno je koristiti jednostavne kontrole povlačenjem i ispuštanjem kako biste objekte i resurse smjestili izravno u 3D okruženje (nije potrebna naknadna obrada!) [2].

Analiza modela – Ima velik paket značajki pomoću kojeg pomaže da se bolje razumije što se dešava. Dubok popis grafikona i grafikona koji pomažu vizualizirati podatke iz simulacije. Mogućnost praćenja širokog raspona podatkovnih točaka, a zatim izvoz u aplikaciju za proračunske tablice (npr. Excel). Ima veću fleksibilnost za prikupljanje podataka putem moćnih alata poput objekta: Sakupljač statistike i aktivnosti zone [2].

Optimizacija – Moguće je testirati scenarije „što ako“ da bi se pronašle najbolje moguće odluke u stvarnom svijetu [2].

Na slici 8. je moguće vidjeti 3D modele i pregled kakav ima program flexsim.

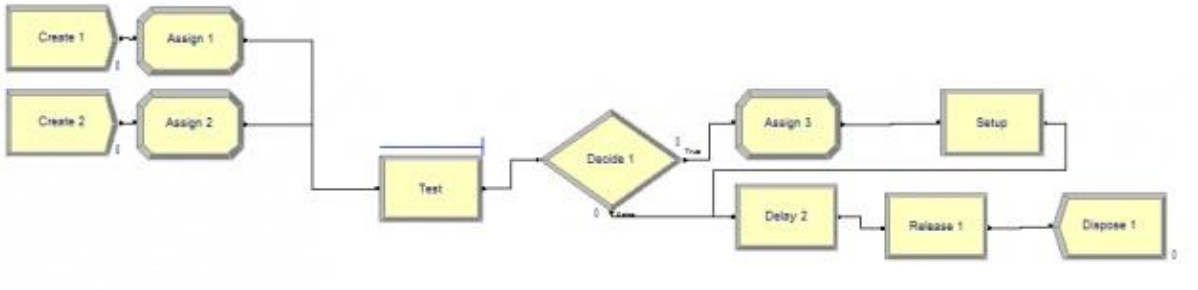


Slika 8: Flexsim prikaz u 3D

Izvor: https://www.flexsim.com/flexsim/ (9.8.2021)

3.2.Arena

Poslovni procesi su prisutni u svakoj vrsti organizacije. Ako su jasno definirani i optimizirani, dobrinjeti će ukupnom uspjehu i profitabilnosti tvrtke. Simulacija ili modeliranje poslovnog procesa daje mogućnost analize i donošenja odluka kako poboljšati taj proces. Arena rockwell je simulacijski alat napravljen od firme Rockwell automation. Arena simulation software širom svijeta koriste tvrtke u različitim industrijama. Na slici 9 može se vidjeti primjer simulacijskog modela u areni [3].



Slika 9: Simulacijski model u areni

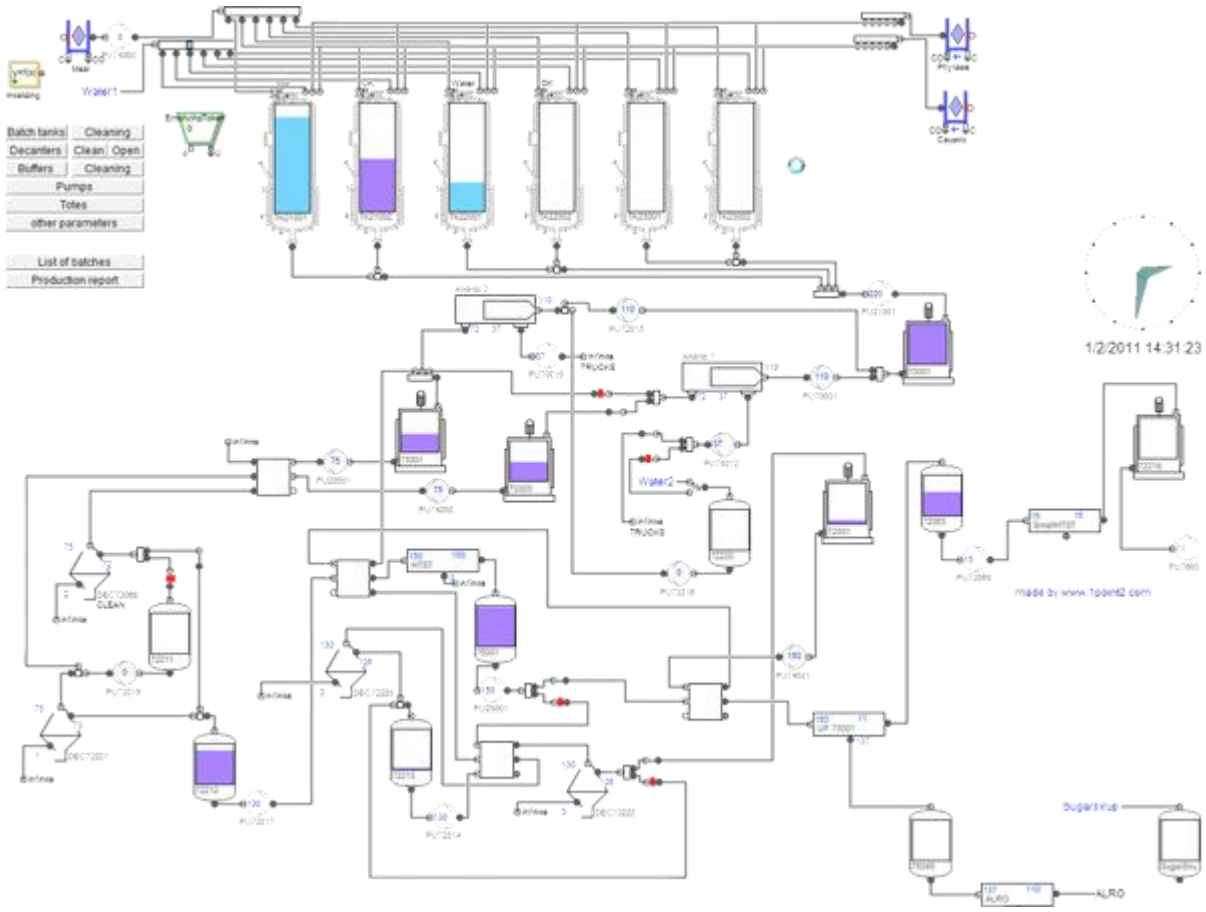
Izvor: https://www.bitlanders.com/blogs/arena-software-a-discrete-event-simulator/5500776 (17.8.2021)

3.3.Extendsim

Extendsim za logistiku, opskrbni lanac i transport može pomoći modeliranjem te neke od funkcija su:

- Nabava, održivost, integrirana logistika, suradnički lanci opskrbe, zakazivanje, razina usluga, mjerenje performansi, upravljanje rizicima i optimizacija procesa
- Globalni logistički menadžment
- Učinkovito integriranje dobavljača, tvornica, skladišta i trgovine kako bi se roba proizvodila i distribuirala u pravim količinama, dolazila na prava mjesta i u pravo vrijeme, a istovremeno smanjila ukupne troškove sustava
- Planiranje u hitnim slučajevima
- Modeliranje prtljage na aerodromu i operacija terminala
- Pomaže odrediti optimalni nivo sigurnosnih zaliha i zaliha ciklusa za oprksbne lance
- Pračenje kretanja tereta kako bi se utvrdila operativna učinkovitost i racionalizirale odluke o planiranju
- Logistika rukovanja kontejnerima za poboljšanje učinkovitosti sustava [4]

Čak i tijekom izvođenja modela, parametri Extendsim-a i logika modela mogu se mijenjati „u hodu“, umjesto da se čeka da simulacija završi. Extendsim-ova hijerarhija omogućuje jedinstvene identitete za svaki blok i dopušta lokalnu upotrebu informacija o bloku. Ponovna upotreba blokova povećava produktivnost, poboljšava dosljednost dizajna i izbjegava ponovno pronalaženje kotača pri svakoj izgradnji novog modela. Na slici 10. se može vidjeti primjer simulacijskog modela u simulacijskom alatu Extendsim [4].



Slika 10: Simulacijski model u Extendsimu

Izvor: https://extendsim.com/products/line/rate (17.8.2021)

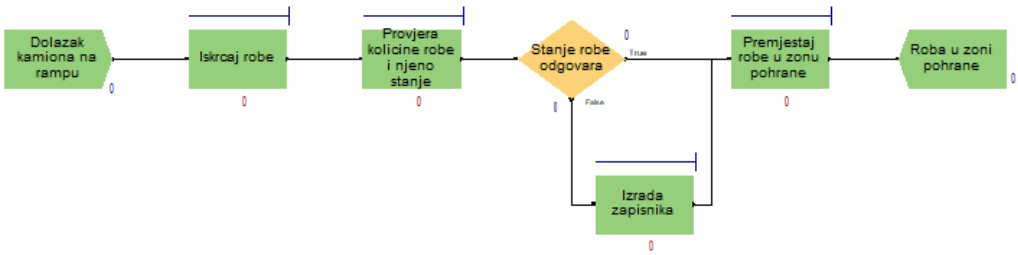
4.Simulacijski model procesa prijema robe u skladište

Koristeći program poput Arene, u mogućnosti smo napraviti simulacijski model procesa prijema robe u skladište, te nakon unešenih parametara dobijemo izvješće u kojem možemo vidjeti npr. koliko paketa se skladišti, koliko paketa ne uspijeva proći iskrcaj za vrijeme simulacije, koliko su vremensko iskorišteni skladištari itd. Na slici 9. je vidljiv primjer simulacijskog modela procesa prijema robe u skladište.

Skladišta služe za čuvanje robe (zaliha), te se iz njih roba prevozi dalje u određena prodajna mjesta. Prvi proces u skladištima sa robom je prijem robe. Skladištu se unaprijed javi broj paketa te broj kamiona koji će dostaviti robu, te se očekuje od skladištara da budu spremni na prijemu. To uključuje više poslova kao npr:

- osiguranje vozila za iskrcaj
- bilježenje podataka o dolasku vozila
- iskrcaj robe iz vozila
- provjera količine robe i njeno stanje
- provjera dokumentacije
- slaganje robe u zonu prijema
- premještanje robe iz zone prijema u zonu pohrane
- izrada dokumentacije za potvrđivanje prijema robe

Na slici 11. je prikazan simulacijski model procesa prijema robe u skladište izrađen u programu Arena, proizvođača Rockwell Automation. Vidljivi su procesi iskrcaja i slaganja robe, provjeravanja stanja robe te prijenosa robe od prijemne zone u zonu pohrane.



Slika 11: Simulacijski model procesa prijema robe u skladište

Izvor: Izradio i oblikovao autor

5.Planiranje i izvođenje simulacijskog eksperimenta

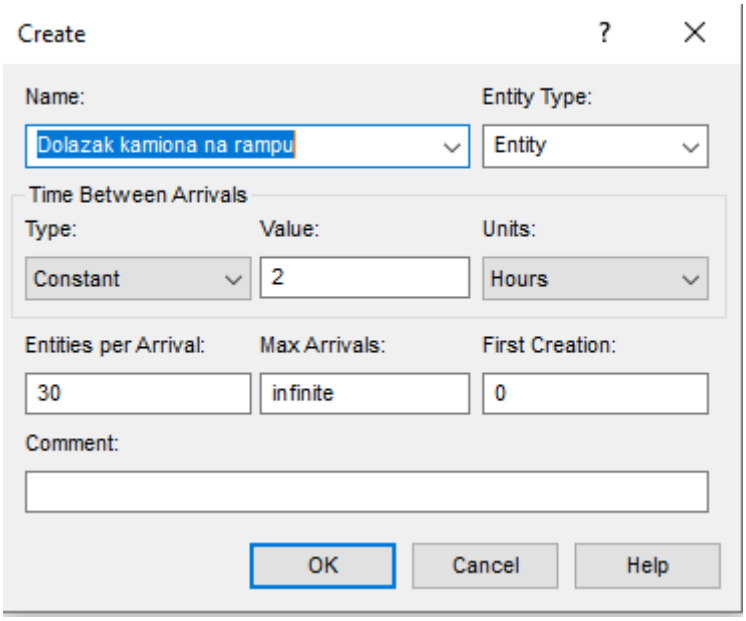
Kako bi se izveo simulacijski proces prijema robe u skladište, koristit će se simulacijski alat Arena rockwell. Potrebno je prvo odrediti parametre simulacije te procese u simulacijskom modelu, te zatim provjeriti razdiobu u svakom procesu, kao i vrijeme obavljanja procesa. U ovom eksperimentu koristit će se isključivo fiktivni podaci za svaki proces. Skladište ima 10 skladištara koji rade na prijemu robe. 4 skladištara radi na iskrcaju i slaganju robe, 2 skladištara rade na provjeri stanja robe, 2 skladištara radi na izradi zapisnika ako je to potrebno, te 2 skladištara rade prebacivanju robe sa prijemne zone u zonu pohrane. 4 kamiona dnevno dovoze robu u skladište te svaki kamion ima 30 paleta u sebi. Raspored dolaska kamiona je unaprijed poznat tako da nije potrebno koristiti razdiobu dolaska. U zadatku je korišteno radno vrijeme od osam sati te se gleda pet radnih dana. U tablici 1. su fiktivni podaci vremena potrebnog za odrađivanje procesa u kojem određeni skladištar sudjeluje. Tablica 1. Predstavlja prosječno vrijeme u minutama koje treba određenom skladištaru da obavi svoj posao. Na temelju vremena iz tablice 1. je napravljena tablica 2. koja služi kao ulazni podatak za input analyzer. Vremena u tablici 2. su pretvorena u decimalni zapis.

Radnik	Vrijeme iskrcaja	Vrijeme provjere stanja	Vrijeme izrade zapisnika	Vrijeme premještaja
1	0:03:36			
2	0:03:05			
3	0:03:03			
4	0:03:13			
5		0:02:30		
6		0:02:32		
7			0:03:12	
8			0:03:06	
9				0:03:08
10				0:03:05

Tablica 1: Vrijeme odrađivanja posla za pojedinog skladištara

Izvor: Izradio autor

Prvi proces je naravno dolazak kamiona na rampu, te je na slici 12. prikazana postavka tog procesa. Četiri kamiona dovoze ukupno 120 paleta dnevno. Kamioni dolaze u razmacima svaka dva sata, te dolaze konstantno tako da nije potrebna teorijska funkcija razdiobe.



Slika 12: Postavke procesa dolaska kamiona na rampu

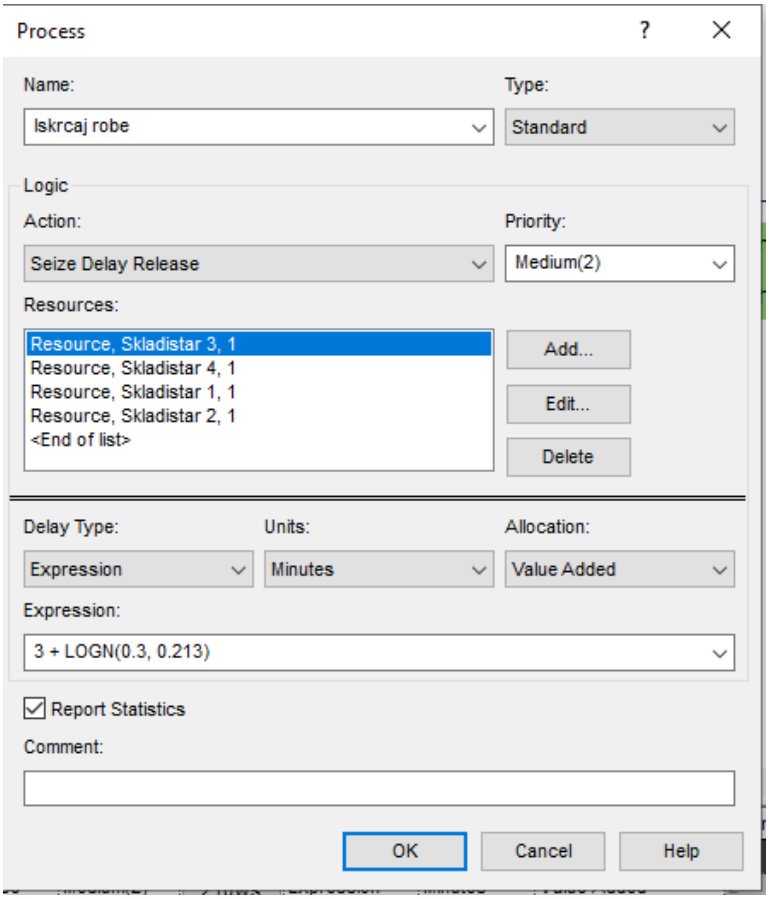
Izvor: Izradio autor

Idući proces je iskrcaj robe iz kamiona u prijemnu zonu. Na slici 13. su prikazane postavke procesa iskrcaja robe. Može se vidjeti da je broj skladištara koji radi na iskrcaju robe četiri, te također „expression“ koji je zadan razdiobom „lognormal“ kroz input analyzer. Slika 14. prikazuje input analyzer koji je odredio tu razdiobu. Na tablici 2. su vremena koja služe kao ulazni podaci za input analyzer. U tablici 1 su vremena u minutama potrebna za svaki proces. U tablici 2 ta vremena između skladištara prebačena u decimalni zapis. Decimalni brojevi se zapišu po redoslijedu, te se spreme kao .text-MS dos datoteka. Tada se taj dokument ubacuje u input analyzer gdje nam on određuje teorijsku funkciju razdiobe. Svaki proces ima 30 uzetih vremenskih uzoraka koji su zabilježeni. Prema njima se za svaki proces zasebno određuje teorijska funkcija razdiobe.

Broj mjerenja	Vrijeme iskrcaja	Vrijeme provjere stanja	Vrijeme izrade zapisnika	Vrijeme premještaja
1	3,1181	2,5	3,123	3,1332
2	3,4323	2,53	3,2	3,1321
3	3,08333	2,51	3,157	3,1111
4	3,05	2,52	3,167	3,0835
5	3,213	2,52	3,123	3,1213
6	3,243	2,51	3,163	3,0891
7	3,466	2,5	3,153	3,0899
8	3,6	2,51	3,123	3,1123
9	3,5432	2,51	3,184	3,1111
10	3,2143	2,52	3,174	3,1231
11	3,2143	2,53	3,135	3,112
12	3,2765	2,533	3,173	3,089
13	3,5436	2,532	3,178	3,08333
14	3,6	2,5332	3,189	3,0934
15	3,3213	2,5332	3,198	3,0964
16	3,2134	2,512	3,195	3,0958
17	3,413	2,5123	3,111	3,0987
18	3,2456	2,5111	3,153	3,1211
19	3,512	2,5132	3,134	3,12
20	3,431	2,5182	3,131	3,0987
21	3,213	2,5151	3,132	3,0965
22	3,211	2,5132	3,134	3,0988
23	3,212	2,5163	3,1432	3,1211
24	3,267	2,5211	3,163	3,1222
25	3,0934	2,5213	3,1423	3,1121
26	3,0911	2,5248	3,146	3,0983
27	3,0963	2,5312	3,199	3,0913
28	3,4132	2,5328	3,154	3,0876
29	3,2123	2,5111	3,143	3,0888
30	3,2211	2,5123	3,173	3,0861

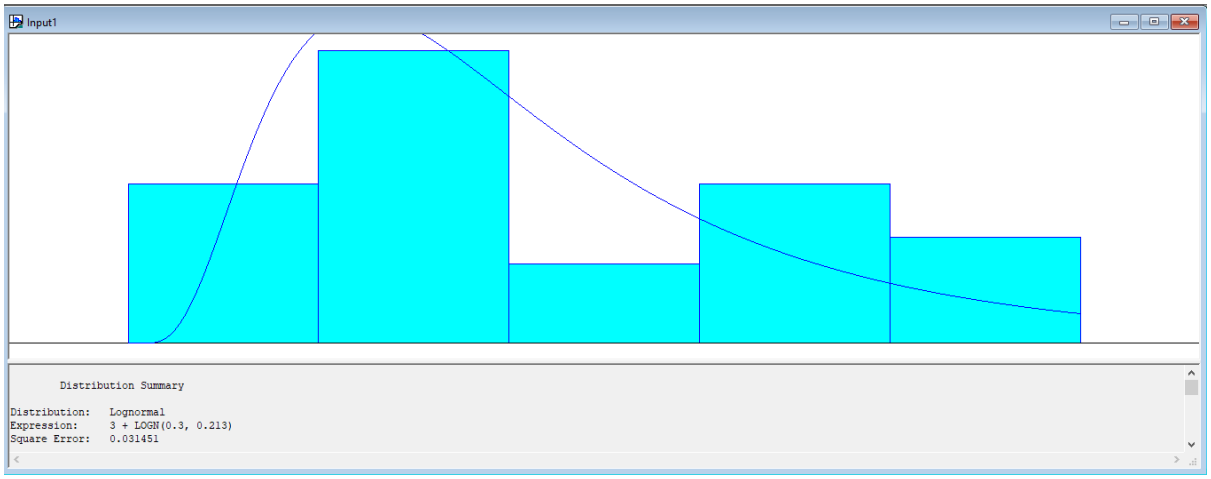
Tablica 2: Ulazni podaci za input analyzer

Izvor: Izradio autor



Slika 13: Postavke procesa „Iskrcaj robe“

Izvor: izradio autor

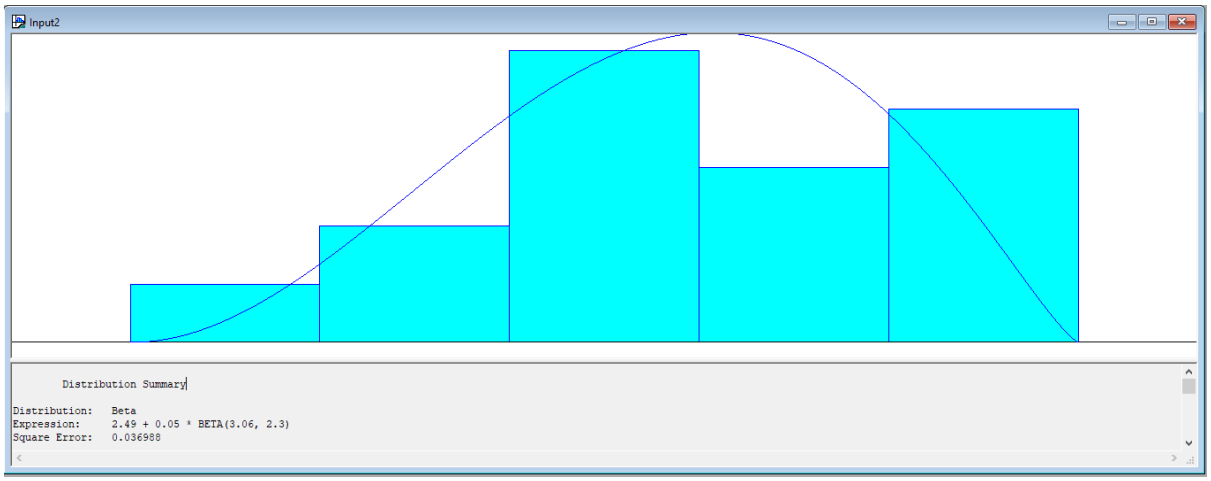


Slika 14: Razdioba vremena za proces iskrcaja robe

Izvor: Izradio autor

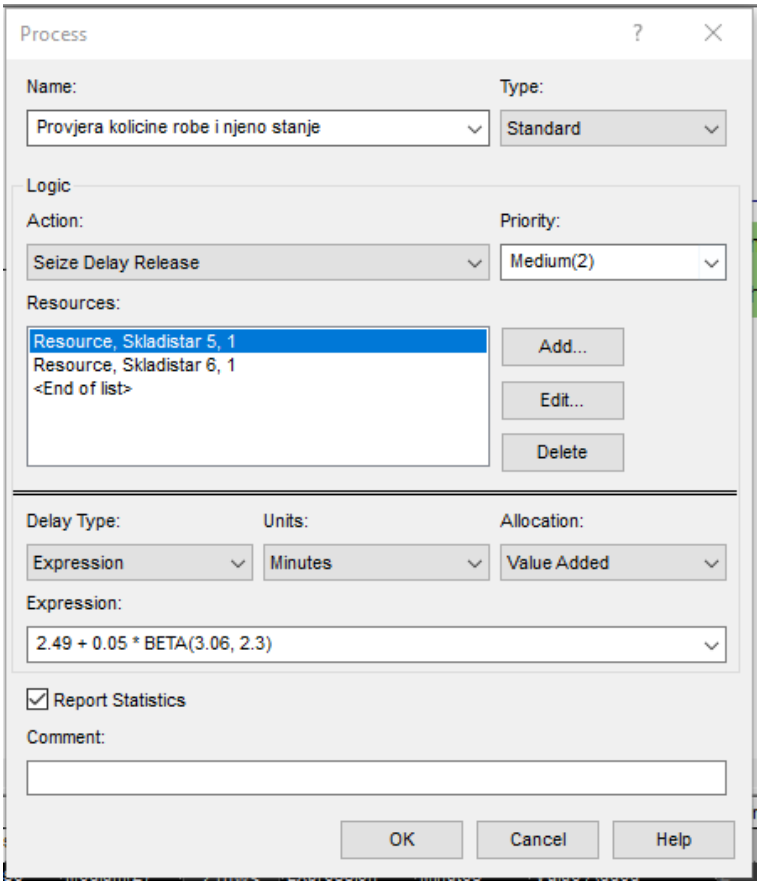
Treći proces je provjera količine robe i njeno stanje te u tom procesu 2 skladištara provjeravaju dali je količina robe onakva kakva je i napisana u dokumentima, te dali je roba

ispravna. U slučaju da nije slijedi izrada zapisnika, a u slučaju da je paleta sa robom se premješta sa viličarom u zonu pohrane. Slika 16. prikazuje postavke procesa, dok je na slici 15. prikazana određena razdioba sa alatom u areni „Input analyzer“. Ulazni podaci za proces su vidljivi na tablici 2. te ubačeni u input analyzer zadaje teorijsku funkciju razdiobe „beta“.



Slika 15: Razdioba vremena za proces kontrole robe

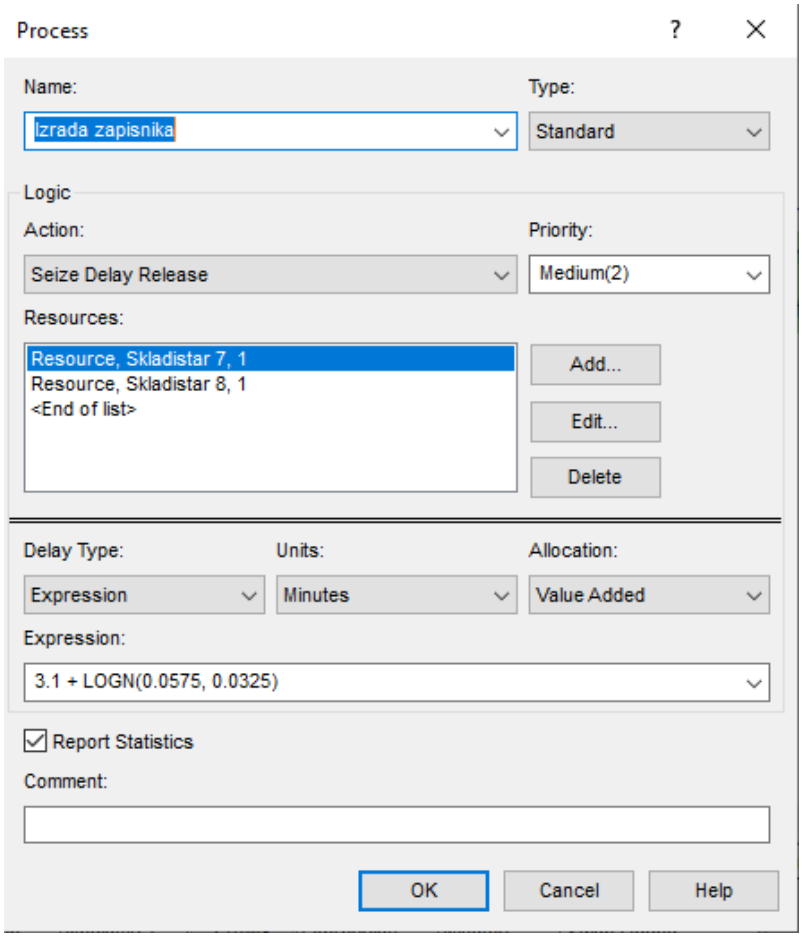
Izvor: Izradio autor



Slika 16: Postavke procesa kontrole robe

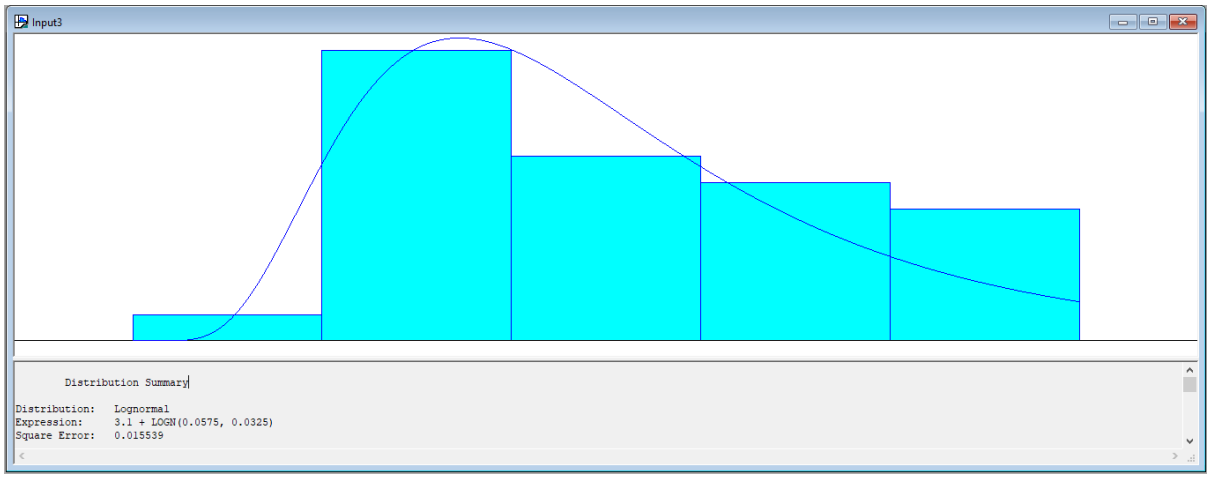
Izvor: Izradio autor

Idući proces ovisi o samoj robi, ako količina i stanje robe odgovara, cijela paleta se premješta iz prijemne zone u zonu pohrane, ako ne odgovara onda se prije toga izrađuje zapisnik. Na slici 17. su prikazane postavke procesa izrade zapisnika na kojoj se vide dva skladištara koja rade na tome. Slika 18. prikazuje razdiobu vremena dobivenu kroz alat „Input analyzer“. Ulaznim podacima iz tablice 2. je dobivena teorijska funkcija razdiobe „lognormal“.



Slika 17: Postavke za proces izrade zapisnika

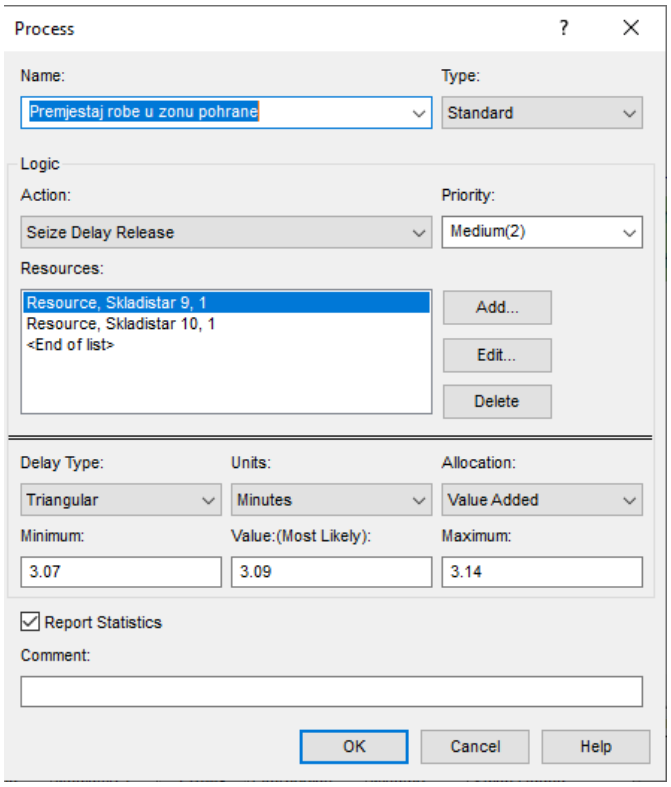
Izvor: Izradio autor



Slika 18: Razdioba vremena procesa izrade zapisnika

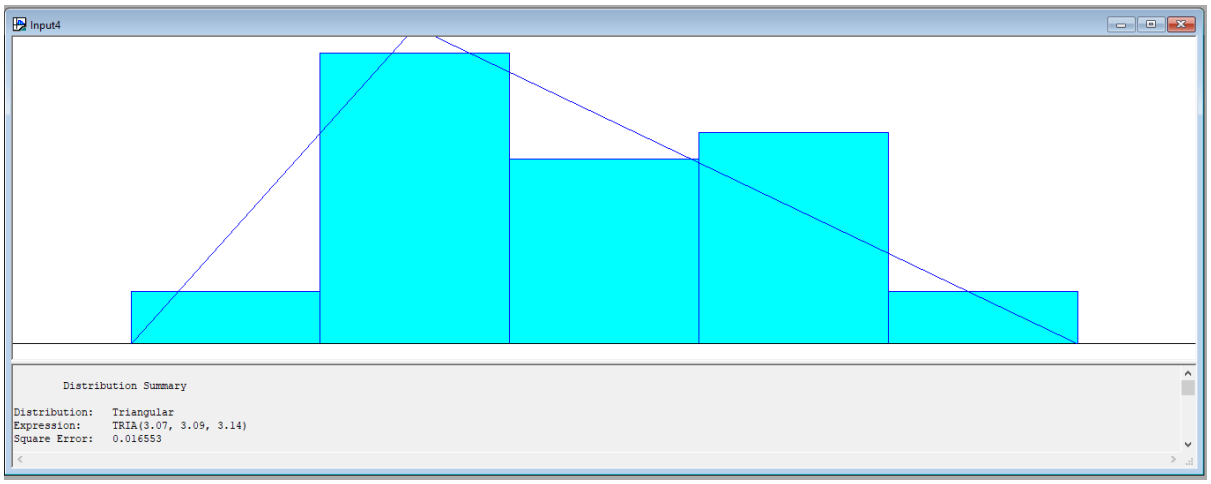
Izvor: Izradio autor

Posljednji proces je premještaj robe u zonu pohrane. Za ovaj proces se obično koriste viličari s kojima se paleta podigne te preveze iz zone prijema do zone pohrane. Na slici 19. su zadane postavke za ovaj proces. Iz slike se vidi da rade 2 skladištara na tome te je zadano trokutastom razdiobom koja je prikazana na slici 20., te dobivena ulaznim podacima iz tablice 2.



Slika 19: Postavke procesa premještaja robe

Izvor: Izradio autor



Slika 20: Razdioba vremena procesa premještaja robe

Izvor: Izradio autor

6.Prikaz rezultata simulacijskog eksperimenta

Nakon izrade simulacijskog modela, provedena je simulacija u trajanju od pet radnih dana s radnim vremenom od 8 sati. Kao rezultati simulacijskog eksperimenta će se gledat zauzetost (iskorištenost) radnika, broj entiteta na izlazu iz sustava, te vremena čekanja entiteta kroz sustav.

Slika 21. prikazuje zauzetost radnika, odnosno koliko su radnog vremena proveli da su bili zauzeti. Maximum i minimum value označavaju najveće moguće opterećenje u postocima (0 % - 100 %), ali s obzirom da radnici imaju sat vremena pauze u osmo-satnom radnom danu, njihovo maksimalno moguće iskorištenje može biti 87,5 %. Slika 21 prikazuje kako skladištari sedam i osam većinu radnog vremena nemaju posla tako da se njih može poslati kao ispomoć na neki drugi skladišni posao dok nemaju posla. Skladištari pet i šest su zauzeti 61,81 % radnog vremena, dok su skladištari na iskrcaju robe zauzeti 81,37 % radnog vremena. Skladištari na premještaju robe su zauzeti 75,83 % radnog vremena. Nijedan radnik u simulaciji nije zauzet svo radno vrijeme koje bi trebao raditi, tj. svih 87,5 % radnog vremena zbog sat vremena pauze.

Number Busy	Average	Half Width	Minimum Value	Maximum Value
Skladistar 1	0.8137	(Insufficient)	0.00	1.0000
Skladistar 10	0.7583	0,092835381	0.00	1.0000
Skladistar 2	0.8137	(Insufficient)	0.00	1.0000
Skladistar 3	0.8137	(Insufficient)	0.00	1.0000
Skladistar 4	0.8137	(Insufficient)	0.00	1.0000
Skladistar 5	0.6181	0,075592412	0.00	1.0000
Skladistar 6	0.6181	0,075592412	0.00	1.0000
Skladistar 7	0.1814	(Insufficient)	0.00	1.0000
Skladistar 8	0.1814	(Insufficient)	0.00	1.0000
Skladistar 9	0.7583	0,092835381	0.00	1.0000

Slika 21: Iskorištenost radnika

Izvor: Izradio autor

Broj entiteta koji je prošao kroz sustav je prikazan na slici 22. 587 entiteta je izašlo iz sustava dok je 630 entiteta ušlo u njega. To nam govori da je 43 entiteta još unutar sustava te da nije došao do zone pohrane u skladištu.

Number In	Value
Entity	630.00

Number Out	Value
Entity	587.00

Slika 22: Broj entiteta kroz sustav

Izvor: Izradio autor

Slika 23. je prikaz vremena čekanja te broja entiteta koji su bili na čekanju na određenom procesu. Vremena u rezultatima su pretvorena u decimalni zapis. Maximum i minimum value označavaju maksimalno/minimalno vrijeme čekanja koje se dešavalo u određenom procesu, dok je za broj entiteta kod number waiting maksimalan broj entiteta koji su u isto vrijeme bili na čekanju u određenom procesu. Average označava prosječan broj entiteta u čekanju kod svakog procesa, ili prosječno vrijeme čekanja po procesu, ovisno o tome da li se gledaju rezultati za waiting time ili number waiting. Najveća gužva, te najviše vremenskog čekanja se događa u procesu iskrcaja robe. Čak 41 entitet odjednom je bio na čekanju u isto vrijeme, dok prosječno na tom procesu čeka otprilike 16 entiteta (zaokruženo na manji cijeli broj). U ostalim procesima nema nekih velikih čekanja, prosječno bude manje od jednog entiteta u njima, dok ih maksimalno u čekanju ne bude više od dva.

Time

Waiting Time	Average	Half Width	Minimum Value	Maximum Value
Iskrcaj robe.Queue	1.0614	0,137576594	0.00	2.6299
Izrada zapisnika.Queue	0.00729286	(Insufficient)	0.00	0.9998
Premjestaj robe u zonu pohrane.Queue	0.03720002	0,011354291	0.00	1.0500
Provjera kolicine robe i njeno stanje.Queue	0.00671032	0,006692333	0.00	0.9889

Cost

Waiting Cost	Average	Half Width	Minimum Value	Maximum Value
Iskrcaj robe.Queue	0.00	0,000000000	0.00	0.00
Izrada zapisnika.Queue	0.00	(Insufficient)	0.00	0.00
Premjestaj robe u zonu pohrane.Queue	0.00	0,000000000	0.00	0.00
Provjera kolicine robe i njeno stanje.Queue	0.00	0,000000000	0.00	0.00

Other

Number Waiting	Average	Half Width	Minimum Value	Maximum Value
Iskrcaj robe.Queue	16.1563	(Correlated)	0.00	41.0000
Izrada zapisnika.Queue	0.04825430	(Insufficient)	0.00	1.0000
Premjestaj robe u zonu pohrane.Queue	0.5689	0,121002964	0.00	2.0000
Provjera kolicine robe i njeno stanje.Queue	0.1217	(Insufficient)	0.00	1.0000

Slika 23: Vrijeme čekanja / broj entiteta na čekanju

Izvor: Izradio autor

7.Zaključak

Simulacijski modeli mogu se primijeniti u analizi postojećih, kao i u dimenzioniranju logističkih sustava i procesa koje tek treba ustrojiti. Sama prednost simulacijskog modeliranja je što se eksperimenti mogu ponavljati sa ili bez promjenjenih parametara, te također služe kao dobar pregled nad modelom koji pokušavamo implementirati. Može pokazati mane promatranog sustava, gdje se može uštediti, da li se nešto radi krivo itd. Primjena simulacijskog modeliranja u logistici je široka, za svaki logistički proces se može izraditi simulacijski model te dodavati potrebne parametre ili ih oduzimati. Prijem robe je samo jedan od logističkih skladišnih procesa za koji će firme izrađivati simulacijski model. Simulacije naravno ne daju potpuno precizne rezultate, zbog stohastičkog karaktera pojedinih varijabli i parametara modela. Ali s obzirom da se logističke firme stalno pokušavaju unaprijeđivati, te istražuju nove načine kako unaprijediti posao, korisno je provoditi simulacijske eksperimente radi analize postojećih logističkih procesa, te također uzimati što više čimbenika u obzir, kako bi simulacije bile preciznije.

Literatura

[1] Čerić, V.: Simulacijsko modeliranje, Školska knjiga, Zagreb, 1993

[2] https://www.flexsim.com/flexsim/ (pristupljeno 17.8.2021)

[3] https://www.rockwellautomation.com/en-us/products/software/arena-simulation.html (pristupljeno 17.8.2021)

[4] https://extendsim.com/ (pristupljeno 17.8.2021)

Popis slika

SLIKA 1: SUSTAVI, MODELI, SIMULACIJA 2
SLIKA 2: DETERMINISTIČKI MODEL 4
SLIKA 3: STOHASTIČKI MODEL 5
SLIKA 4: DISKRETNI MODEL 5
SLIKA 5: KONTINUIRANI MODEL 6
SLIKA 6: KONTINUIRANO-DISKRETNI MODEL 6
SLIKA 7: RAČUNANJE ODREĐENOG INTEGRALA, MONTE CARLO SIMULACIJA 8
SLIKA 8: FLEXSIM PRIKAZ U 3D 13
SLIKA 9: SIMULACIJSKI MODEL U ARENI 13
SLIKA 10: SIMULACIJSKI MODEL U EXTENDSIMU 15
SLIKA 11: SIMULACIJSKI MODEL PROCESA PRIJEMA ROBE U SKLADIŠTE 16
SLIKA 12: POSTAVKE PROCESA DOLASKA KAMIONA NA RAMPU 18
SLIKA 13: POSTAVKE PROCESA „ISKRCAJ ROBE“ 20
SLIKA 14: RAZDIOBA VREMENA ZA PROCES ISKRCAJA ROBE 20
SLIKA 15: RAZDIOBA VREMENA ZA PROCES KONTROLE ROBE 21
SLIKA 16: POSTAVKE PROCESA KONTROLE ROBE 22
SLIKA 17: POSTAVKE ZA PROCES IZRADE ZAPISNIKA 23
SLIKA 18: RAZDIOBA VREMENA PROCESA IZRADE ZAPISNIKA 23
SLIKA 19: POSTAVKE PROCESA PREMJEŠTAJA ROBE 24
SLIKA 20: RAZDIOBA VREMENA PROCESA PREMJEŠTAJA ROBE 24
SLIKA 21: ISKORIŠTENOST RADNIKA 25
SLIKA 22: BROJ ENTITETA KROZ SUSTAV 26
SLIKA 23: VRIJEME ČEKANJA / BROJ ENTITETA NA ČEKANJU 27

Popis tablica

TABLICA 1: VRIJEME ODRAĐIVANJA POSLA ZA POJEDINOG SKLADIŠTARA.....17
TABLICA 2: ULAZNI PODACI ZA INPUT ANALYZER.....19

Sveučilište u Zagrebu
Fakultet prometnih znanosti
10000 Zagreb
Vukelićeva 4

IZJAVA O AKADEMSKOJ ČESTITOSTI I SUGLASNOST

Izjavljujem i svojim potpisom potvrđujem kako je ovaj završni rad isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu što pokazuju korištene bilješke i bibliografija.

Izjavljujem kako nijedan dio rada nije napisan na nedozvoljen način, niti je prepisan iz necitiranog rada, te nijedan dio rada ne krši bilo čija autorska prava.

Izjavljujem također, kako nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Svojim potpisom potvrđujem i dajem suglasnost za javnu objavu završnog rada pod naslovom **PRIMJENA SIMULACIJSKOG MODELIRANJA U ANALIZI PROCESA PRIJEMA ROBE U SKLADIŠTE**

na internetskim stranicama i repozitoriju Fakulteta prometnih znanosti, Digitalnom akademskom repozitoriju (DAR) pri Nacionalnoj i sveučilišnoj knjižnici u Zagrebu.

U Zagrebu, 8/31/2021

Student/ica:



(potpis)