



4. Simulacijsko modeliranje i analiza

Simulacijskim modeliranjem i analizom (engl. *simulation modelling and analysis* - SMA) nastoje se ispuniti zahtjevi Conant–Ashby teorema (Conant i Ashby, 1970), definirajući model sustava kao dobrog regulatora, koji ima onoliko ručki, dijelova i stanja koliko i njegov izvorni fizički pandan. Time pruža mogućnost izgradnje svog digitalnog modela i uspostavljanja digitalnog laboratorija koji će omogućiti njegovo istraživanje, prilagodbu i optimizaciju. Rezultirajući simulacijski modeli su apstraktni, dinamički i u većini slučajeva stohastični, budući da su njihove varijable sustava modelirane distribucijama vjerojatnosti.



4.1 Simulacija u logistici

U logistici SMA može pružiti vrijedne inpute za optimizaciju opskrbnog lanca (engl. *supply chain* - SC) i prometne mreže (engl. *traffic network* - TN). Simulacijsko modeliranje može se koristiti za grafičku vizualizaciju vremenskih tokova kroz složene SC i TN procese i resurse, omogućujući predviđanje i kvantifikaciju mogućih ishoda iz različitih scenarija. Ovo pomaže SC i TN entitetima da steknu dragocjene uvide i razumiju učinke svojih potencijalnih odluka na SC i TN izvedbu uključujući SC vremena dostave (engl. *lead-times*), TN vrijeme putovanja i troškove. Stoga, SMA u SC i TN modeliranju može doprinijeti SC i TN analizi i poboljšanju njihovih dizajna prema postizanju veće učinkovitosti i održivosti.

Postoje mnogi aspekti SC-a, koji predstavljaju različite perspektive upravljanja opskrbnim lancem. Pogled menadžera proizvodnje na opskrbni lanac razlikuje se od pogleda menadžera marketinga, koji se opet razlikuje od pogleda menadžera nabave, itd. Dakle, korišteni modeli su različiti, čak i za istu tvrtku, a osobito za cijeli SC.

Prilikom rješavanja problema SMA u logistici, menadžeri trebaju donositi odluke na strateškoj, taktičkoj i operativnoj razini, ovisno o njihovom učinku na SC ili TN u cjelini. Zbog svoje međuovisnosti, menadžeri često nisu u stanju riješiti probleme ni na jednoj razini. Istodobno, također je teško promatrati sve tri razine iz perspektive bilo koje pojedinačne cjeline. Iz perspektive SMA, SC ili TN se mogu promatrati na dvije razine:



1. Makro razina

- samoorganizacija,
- koevolucija entiteta,
- ovisnost o vezama/transportnim rutama.

2. Mikro razina

- višestruki i heterogeni entiteti,
- lokalne interakcije među entitetima,
- strukturirani entiteti,
- adaptivni entiteti.

Iako se izvode u stvarnom vremenu, vremenski aspekt SC operacija je donekle dvosmislen. Ovisno o razini i perspektivi, trajanje operacija može se mjeriti u danima, tjednima ili čak mjesecima kada su u pitanju među-organizacijske aktivnosti, dok se s druge strane, unutar-organizacijske operacije mjere u satima ili čak sekundama. Ovisno o prirodi modeliranog problema, trajanje najkraće operacije ili maksimalna učestalost dolaznih/odlaznih zahtjeva određuje ne samo prikaz vremena u SMA modelu, već i njegovu granularnost. Što je kraće minimalno trajanje najkraće operacije ili što je veća učestalost zahtjeva, to je finija granularnost vremena, odnosno preciznost vođenja vremena u modelu. Ovo je važno za modelara, budući da vrijeme reakcije modela ne može biti kraće od unaprijed definirane vremenske granularnosti. Stoga je potrebno unaprijed procijeniti trajanje svih operacija i vremena između dolazaka dolaznih/odlaznih signala kako bi se mogle ispravno odrediti vremenske jedinice modela sustava.

U simulacijskom modelu vrijeme može napredovati kritičnim događajima od transakcije do transakcije ili kontinuirano. U potonjem slučaju, tijek vremena u modelu ne ovisi o učestalosti operacija. S protokom vremena pokrenutog kritičnim događajem, operacije se pozivaju prema vremenu njihovog pojavljivanja, odnosno kritičnih događaja. Prednost SMA je u tome što se tijekom simulacije može ubrzati tijek vremena u modelu, tako da se procesi izvode brže nego u stvarnom vremenu. Stoga se mogu napraviti rana predviđanja sljedećih događaja.

Vremena između dolaznih simulacijskih jedinica i vremena njihove obrade/tranzita mogu proizaći iz promatranja i mjerenja. Ako ne variraju, onda su deterministički. Međutim, obično



su po svojoj prirodi stohastične. Stoga, potrebno je uvođenje konstrukata koji modeliraju njihove funkcije distribucije vjerojatnosti (npr. trokutaste, uniformne, eksponencijalne, itd.).

4.2 Simulacija diskretnog događaja



Simulacija diskretnog događaja (engl. *discrete event simulation* – DES) nudi voditelju proizvodnje najdetaljniji uvid u logistički (proizvodni) proces po konzistentnom i koherentnom modelu. Stoga je DES visoko cijenjen alat za određivanje ponašanja i iskorištenja resursa u stvarnom vremenu u procesnoj industriji, uključujući logistiku.

Konstrukti:

- Jedinice toka predstavljaju jedinice simulacije (npr. narudžbe, materijali itd.) koje ulaze u sustav na ulazu(ima) i napreduju kroz model sustava.
- Procesori predstavljaju mobilne (npr. ljudi, viličari itd.) i fiksne (npr. strojevi, proizvodne linije itd.) resurse koji obrađuju simulacijske jedinice.
- Redovi čekanja pohranjuju jedinice toka do njihovog prijelaza na sljedeći dostupni procesor.
- Konektori definiraju promicanje jedinica kroz model sustava.


Svojstva:

- Orijentiran na proces.
- Fokusira se na detaljno modeliranje procesa.
- Heterogeni entiteti.
- Mikro-entiteti su pasivni objekti.
- Događaji unose dinamiku u sustav.
- Diskretna vremenska progresija; od jednog (vremenskog) događaja do sljedećeg.
- Fleksibilnost se postiže promjenom strukture modela; struktura sustava tijekom simulacije je fiksna.



Primjer

Primjer DES-a (Slika 4.1, iz simulacijskog okruženja JaamSim (JaamSim Development Team, 2023)) uključuje model varijante proizvodnje, gdje se proizvode četiri različita proizvoda (Gumzej i Rakovska, 2020). Prema planu proizvodnje, proizvodi se 10, 30, 40, 20% proizvoda vrste 1, 2, 3, odnosno 4. Odabir vrste proizvoda potaknut je trokutastom raspodjelom između 1 i 4 s modulom na 3. Svaka vrsta proizvoda ima namjensku proizvodnu liniju. Proizvodni nalozi se ispunjavaju prema eksponencijalnoj distribuciji oko srednje vremenske vrijednosti od 30 s. Proizvodnja svakog pojedinog proizvoda traje 100-120s prema ravnomjernoj distribuciji. Nakon što su finalizirani, kvaliteta proizvoda se provjerava na namjenskom ispitnom mjestu. Provjera kvalitete traje 10 s. Iz iskustva tvrtke, u prosjeku svaki 1 od 10 proizvoda ne prođe kontrolu. Proizvodi nedovoljne kvalitete transportiraju se natrag na izvornu proizvodnu liniju. Njihova ponovna obrada traje 120-130s prema ravnomjernoj raspodjeli. Trajanje proizvodnje i kontrole kvalitete te ponovne obrade ne ovise o vrsti proizvoda. Nakon što su uspješno prošli kontrolu kvalitete, gotovi proizvodi se transportiraju s mjesta proizvodnje u skladište gotovih proizvoda. Ponovna proizvodnja neispravnih proizvoda dok su još u proizvodnji učinkovit je način smanjenja utjecaja na okoliš i troškova proizvodnje.



Slika 4.1 Varijanta proizvodnje s kontrolom kvalitete.



Sinopsis

DES može analizirati i optimizirati sljedeće procesne parametre:

- Vrijeme proizvodnog ciklusa i učinak.
- Iskorištenost proizvodnih ćelija i prostora.
- Kapacitet skladišnih prostora kao i vrijeme zadržavanja skladišnih jedinica.
- Korištenje mobilnih resursa (npr. operateri, pokretne trake, viličari).

4.3 Sustavna dinamika



Analiza sustavna dinamika (engl. *system dynamics* – SD) predstavlja pogled menadžera SC-a na proizvodni proces pomoću dosljednog i koherentnog modela. SD se smatra alatom koji je najprikladniji za određivanje strukture, kao i optimalnih količina (za pojedinačnu lokaciju kada i koliko inputa, zaliha i outputa. Stoga, omogućuje učinkovito korištenje proizvodnih i skladišnih objekata.

Konstrukti:

- Zalihe predstavljaju tampone koji mogu pohraniti stavke isporuke u opskrbnom lancu.
- Tokovi predstavljaju opskrbne kanale.
- Petlje povratne sprege predstavljaju parametre finog podešavanja za nadopunjavanje zaliha.

Svojstva:


- Usmjeren na sustav.
- Modeliranje varijabli sustava usmjereno na ključne pokazatelje učinka.
- Homogeni entiteti.
- Entiteti na mikrorazini se zanemaruju.
- Dinamika se uvodi petljom povratne sprege.
- Kontinuirana vremenska progresija; vrijeme napreduje sinkronizirano za sve komponente modela sustava.



- Fleksibilnost se postiže promjenom strukture modela.
- Struktura sustava tijekom simulacije je fiksna.

Primjer

Primjer SD-a (Slika 4.2, iz simulacijskog okruženja NetLogo (Wilensky, 1999)) obuhvaća opskrbni lanac tvrtke kućanskih aparata i opisuje tokove materijala između njezinih podružnica (Gumzej i Rakovska, 2020). Tvrtka ima više proizvodnih lokacija: glavnu lokaciju u Sloveniji (SI) kao i podružnice u Njemačkoj (DE), Poljskoj (PL), Mađarskoj (H) i Bosni i Hercegovini (BIH). Uz proizvodna mjesta, njegova veleprodajna mjesta nalaze se u Rusiji (RUS), Ukrajini (UKR) i Rumunjskoj (RU). Proizvodne lokacije opskrbljuju vlastita tržišta gotovim proizvodima i jedna drugu komponentama proizvoda.




Slika 4.2 Layout opskrbnog lanca.

Povezana NetLogo nadzorna ploča (slika 4.3) služi kao alat za podršku odlučivanju (engl. *decision support tool* - DST), za povezivanje proizvodnje i količina zaliha s predispozicijama i njihovom fizičkom distribucijom. Vremenski tijek je kontinuiran kroz svakodnevne transakcije, tj. svaki dan se određeni broj komponenti isporučuje između proizvodnih mjesta i određeni broj gotovih proizvoda se troši na licu mjesta ili se otprema na mjesta distribucije. Na temelju početnih zaliha od 300 jedinica na SI lokaciji, 0 zaliha na drugim lokacijama i modela



distribucije, količine zaliha na pojedinačnim lokacijama predstavljaju prosječne zalihe prema danoj proizvodnji (kom), potrošnji (%) i otpremi (%).



Slika 4.3Nadzorna ploča opskrbnog lanca.

Sinopsis

Simulacija sustavne dinamike omogućuje:

- Planiranje layouta SC-a.
- Optimizacija proizvodnih i distribucijskih kapaciteta.
- Procjena opterećenja kanala distribucije i povezanih troškova.

4.4 Simulacija temeljena na agentima

Simulacija temeljena na agentima (engl. *agent-based simulation* – ABS) analiza nudi pogled na tržište od strane strateškog menadžera ili regulatora tržišta. Stoga se ABS smatra alatom koji je najprikladniji za određivanje optimalne strukture i rasporeda/asortimana nečijeg tržišta i/ili





SC-a uzimajući u obzir njihove globalne karakteristike (npr. demografiju, klimu, BDP, kvalitetu, svijest, itd.).

Konstrukti:


Agenti koji predstavljaju čvorove opskrbnog lanca (npr. dobavljači, trgovci na malo i inspektori) sa svojim svojstvima, odnosima i ponašanjem.

Svojstva:

- Usredotočen na entitet.
- Problemski orijentirano modeliranje entiteta i njihovih interakcija.
- Heterogenost entiteta.
- Mikro-entiteti su aktivni objekti koji djeluju u svom okruženju, međusobno komuniciraju i samostalno donose odluke.
- Odluke i interakcije između agenata unose dinamiku u sustave.
- Agenti i njihovo okruženje čine formalne modele.
- Protok vremena je diskretan i univerzalan na razini modela; vrijeme modela je u skladu s učestalošću SC transakcija i životnim ciklusima SC čvorova.
- Fleksibilnost modela postiže se promjenom strukture sustava i ponašanja agenata.
- Struktura sustava tijekom simulacije je promjenjiva.

Primjer

Primjer ABS-a (slika 4.4, iz simulacijskog okruženja NetLogo (Wilensky, 1999)) korišten je za analizu ponašanje ešalona opskrbnog lanca na otvorenom tržištu (Gumzej i Rakovska, 2020), s obzirom na njihovu kvalitetu usluge (engl. *Quality of Service* - QoS). U primjeru, različite politike koje se tiču ukupnog upravljanja kvalitetom tvrtke istraživane su modelom koji se sastoji od dobavljača, kupaca i regulatora tržišta.



Slika 4.4Regulacija tržišta.

Sinopsis

Simulacija temeljena na agentima omogućuje:

- Planiranje layouta SC-a.
- Modeliranje dinamičkog rasta SC-a.
- Modeliranje ponašanja partnera unutar SC-a.
- Optimizacija globalnih pokazatelja.

4.5 Simulacija mreže



Simulacija mreže (engl. *network simulation* – NS) analiza nudi mrežni regulatorni pogled na mrežu. Stoga se NS smatra alatom koji je najprikladniji za određivanje optimalne strukture, rasporeda i asortimana vlastite mreže uzimajući u obzir njezine globalne karakteristike (npr. propusnost, emisije, QoS pokazatelji, itd.).

Konstrukti:

Agenti koji predstavljaju objekte toka s njihovim svojstvima, odnosima i ponašanjem.




Mreža koja predstavlja mrežu preklapanja (npr. prometnu mrežu) na kojoj se objekti toka kreću.

Svojstva:

- Usmjeren na sustav.
- Problemski orijentirano modeliranje entiteta i njihovih interakcija.
- Heterogenost entiteta.
- Mikro-entiteti su aktivni objekti koji djeluju u svom okruženju, međusobno komuniciraju i samostalno donose odluke.
- Odluke i interakcije između agenata unose dinamiku u sustave.
- Agenti i njihovo okruženje čine formalne modele.
- Protok vremena je diskretan i univerzalan na razini modela; vrijeme je u skladu s relativnim brzinama objekata toka.
- Fleksibilnost modela postiže se promjenom mrežne strukture koja se fiksira tijekom simulacije i ponašanja agenata koji variraju ovisno o stanju (prometa) mreže i njihovim ciljevima.

Primjer

Predstavljeni primjer (slika 4.5, iz SUMO (Pablo et.al., 2018.) simulacijskog okruženja) korišten je za određivanje prometnih tokova i propusnosti ulica u središtu grada pogođenih planiranom blokadom ceste (Šinko i Gumzej, 2021). Osim toga, mjereni su pokazatelji povezani s prometom poput vremena putovanja, potrošnje goriva i emisija.



Slika 4.5 Prometna situacija i mreža.

Sinopsis

Mrežna simulacija omogućuje:

- Planiranje layouta mreže.
- Modeliranje dinamičkog ponašanja mreže za određivanje uskih grla i slabih veza.
- Modeliranje toka mrežnih stavki.
- Optimizacija pokazatelja globalne mreže.

4.6 Projekti logističke simulacije

Projekti logističke simulacije dizajnirani su u skladu s paradigmom Dizajn za šest sigma (engl. *Design for Six Sigma* - DFSS) i temelje se na Demingovom ciklusu poboljšanja:




- Planiranje: definiranje sustava i ciljeva.
- Izvedba: dizajn simulacijskog modela.
- Analiza: eksperimentiranje sa simulacijskim modelom i procjena alternativa.
- Radnja: korištenje rezultata simulacije za implementaciju poboljšanja.

Svaki projekt logističke simulacije (slika 4.6) sastoji se od sedam faza:



1. Strateški plan: analiza postojećih i predloženih resursa i procesa.
2. Konceptualni model: apstraktni model sustava i definicija predispozicija, prikupljanje podataka.
3. Logički model: tok objekta, zalihe i tok ili mrežni dijagram modela sustava.
4. Simulacijski model: izrada odgovarajućeg simulacijskog modela.
5. Verifikacija i validacija simulacijskog modela: provjera konzistentnosti i koherentnosti modela.
6. Analiza na temelju simulacijskog modela: dizajn i izvedba eksperimenta.
7. Korištenje rezultata simulacije za izradu akcijskog plana: projekcija poboljšanja sustava.



Slika 4.6 Proces simulacijskog modeliranja i analize (SMA).

4.7 Zaključak

U logistici je SMA važna komponenta operacijskog istraživanja (OR) koja omogućuje optimizaciju procesa.



Sustavna dinamika (SD) je metodologija za analizu složenih, dinamičkih i nelinearnih interakcija u sustavima, što rezultira novim strukturama i politikama za poboljšanje ponašanja sustava. Ovdje se rješavaju fizički i informacijski tokovi s ciljem smanjenja njihovog kašnjenja i konačno zaliha u opskrbnom lancu.

Druga popularna procesno orijentirana metodologija je simulacija diskretnih događaja (DES). To je jedan od najčešće korištenih i najfleksibilnijih analitičkih alata u SMA proizvodnih sustava. Uspješno se nosi s neizvjesnošću i pruža mogućnosti usporedbe alternativnih načina za smanjenje vremena isporuke kao i optimizaciju korištenja strojeva i resursa.

Korisna metodologija za razumijevanje ponašanja organizacija i njihovih interakcija (npr. opskrbnih lanaca i njihovih entiteta) je simulacija temeljena na agentima (ABS). Simulacija mreže (NS), kao posebna vrsta ABS-a, omogućuje modeliranje i optimizaciju (prometnih) preklopnih mreža.

To dovodi do zaključka da holistički pristup primjene SMA u logistici uvelike doprinosi složenim odlukama o dizajnu sustava, gdje postoji mnogo varijabli koje međusobno djeluju. Koristan integrirani pristup, uključujući metodologije SD, DES i ABS, koji može kvantificirati protoke na različitim razinama opskrbnog lanca, predstavljen je u (Gumzej & Rakovska, 2020). U analizi i optimizaciji prometnog toka, NS metodologija pruža potreban okvir u vezi s praćenjem i finim podešavanjem ključnih pokazatelja uspješnosti (Šinko i Gumzej, 2021).

LITERATURA 4. POGLAVLJA

- Conant R.C. and Ashby W.R. (1970). Every good regulator of a system must be a model of that system, *Int. J. Systems Sci.*, 1(2), pp. 89-97.
- Gumzej, R. and Rakovska, M. (2020). Simulation modeling and analysis for sustainable supply chains. In *Ecoproduction – Sustainable logistics and production in industry 4.0 : new opportunities and challenges*, Grzybowska, K., Awasthi, A., Sawhney, R. (ed.). Springer Nature, pp. 145-160.
- JaamSim Development Team (2023). JaamSim: Discrete-Event Simulation Software. Version 2023-08. [Available at: <https://jaamsim.com>, access November 8th, 2023]
- Šinko, S. and Gumzej, R. (2021). Towards smart traffic planning by traffic simulation on microscopic level. *International journal of applied logistics*, 11(1), pp. 1-17.



- Wilensky, U. (1999). NetLogo. Center for Connected Learning and Computer-Based Modeling, Northwestern University, Evanston, IL. [Available at: <http://ccl.northwestern.edu/netlogo/>, access November 8th, 2023]
- Pablo A.L., Behrisch, M., Bieker-Walz, L., Erdmann, J., Flötteröd, Y.-P., Hilbrich, R., Lücken, L., Rummel, J., Wagner, P. and Wießner, E. (2018). Microscopic Traffic Simulation using SUMO. In: 2019 IEEE Intelligent Transportation Systems Conference (ITSC), IEEE. The 21st IEEE International Conference on Intelligent Transportation Systems, 4.-7. Nov. 2018, Maui, USA, pp. 2575-2582.