

# SIMULACIJSKO MODELIRANJE U PROCESU ODLUČIVANJA

## SIMULATION MODELLING IN DECISION-MAKING PROCESS

**Dr. Vesna Dušak**

Fakultet organizacije i informatike, Varaždin

*Simulacije se često upotrebljavaju kao pomoć u procesu odlučivanja. Tema rada je uloga simulacija u procesu odlučivanja i razlozi zašto su simulacije pri tome tako značajna pomoć. Također su obrađeni i suvremeni pristupi simulacijski-baziranoj programskoj podršci.*

*Simulation is one of the most widely used aids in decision-making process. This article deals with the role of simulation in decision-making and reasons why the simulation is a powerful tool in that process. Also, the new approaches to simulation-based software as an aid in decision-making process is described.*

**Ključne riječi:** Odlučivanje, simulacija, optimalizacija

**Keywords:** Decision-Making, Simulation, Optimisation

---

### 1. UVOD

Uvažavajući činjenicu da su kvantitativno modeliranje i element odlučivanja bitni za identifikaciju operacijskih istraživanja, možemo prihvatiti Rhienshartovu definiciju (11) da su operacijska istraživanja "znanost o odlučivanju". Prema tome, tehnike operacijskih istraživanja su snažno sredstvo za donošenje dobrih odluka.

Operacijska istraživanja su problemski orijentirana disciplina. Problemi se oblikuju prema cilju koji treba postići pod različitim okolnostima i sposobnostima istraživača. Prilikom rješavanja problema moguće je koristiti problemski orijentirane tehnike (modeli repova čekanja, modeli zaliha, modeli održavanja, ...) i tehnike orijentirane načinu rješavanja problema (matematičko programiranje, dinamičko programiranje, heurističko programiranje, simulacije, ..). Ponekad je vrlo korisno služiti se nekom kombinacijom tih tehnika.

Simulacije se koriste kod modeliranja problema koji nisu pogodni za klasični matematički ili numerički pristup i ne daju obično optimalno rješenje. Kao što je Shannon definirao (13) simulacije su "proces dizajniranja kompjutoriziranog modela sustava (ili procesa) i vođenje eksperimenata s tim modelom u svrhu razumijevanja ponašanja sustava ili razvoja različitih strategija operiranja sustavom".

Uloga simulacija je izuzetno velika kod modeliranja sustava s povratnom vezom i simuliranja njihove dinamike. Takvi su sustavi izuzetno složeni tako da postoje poteškoće njihove direktne analize kada se oni, kao što je uobičajeno, rješavaju preko sustava diferencijalnih jednačbi. Ove je probleme djelomično moguće izbjeći zamjenom diferencijalnih jednačbi diferencijskim jednačbama prvog stupnja.

## 2. SIMULACIJSKO MODELIRANJE KAO PODRŠKA ODLUČIVANJU

Simulacije se vrlo često koriste kao pomoć u procesu odlučivanja. Vrlo širok pregled uporabe simulacijskog modeliranja na svim nivoima i funkcionalnim područjima američkih poduzeća dali su Cox, Ledbetter i Smith (1) za 1975. i Nelson, Bradbord, Cox i Ledbetter (8) za 1985. godinu. U obje studije primijenjena je ista metodologija istraživanja i prikazivanja rezultata što omogućuje njihovu usporedbu. Autori su istraživali učestalost primjene simulacijskog modeliranja na svim nivoima odlučivanja kao strateška, operativna i taktička podrška. Usporedba rezultata ovih studija pokazala je kroz promatrano razdoblje značajan porast upotreba simulacija na operativnom nivou (u 1985. godini 38.2% poduzeća često je na tom nivou upotrebljavalo simulacije).

Promatrajući upotrebu simulacija u funkcijskim područjima poduzeća, proizvodnja je područje koje se posebno ističe. Također je porastao i stupanj upotrebe simulacija u području marketinga, dok je opao u području financija. Ovo je moguće objasniti razvojem visoko funkcionalne programske podrške za simulaciju i njezinim direktnim uključivanjem u proizvodno/procesnu i marketinšku funkciju.

Uzevši rezultate ovih studija u cijelosti, ne može se reći da je upotreba simulacijskog modeliranja naglo porasla od 1975. godine. Autori navode nekoliko razloga: 1. simulacijsko modeliranje je isuviše sofisticirano i traži previše vremena da bi se moglo primjenjivati za brzo donošenje odluka i 2. metode operacijskih istraživanja su integrirane u funkcionalna područja organizacija te predstavljaju njihovu decentralizaciju.

Uloga simulacija u donošenju odluka predmet je bavljenja time niza radova Nagela i njegovih asistenata (6,7,8). Ovi se radovi bave simulacijama u svrhu donošenja, utjecaja, predviđanja i objašnjavanja odluka. U tu su svrhu autori zaokupljeni dedukcijom motiva i percepcija promatrajući ranije donijete odluke (čak odluke iz dalje prošlosti), vrednujući ih, promatrajući sredstva i načine na koje su donijete, a u svrhu objašnjavanja uzroka njihova nastanka.

Autori prikazuju bazične silogističke forme simulacije procesa donošenja odluka i razmatraju mogućnost zaključivanja na osnovi ranijih odluka. Ovaj proces ovisi o znanju i umijeću donosioca odluke, o samom slučaju, kao i odnosima između elemenata bitnih za donošenje odluka (posebno o mogućim alternativama). Najznačajniji efekt određivanja motiva i rekonstrukcije odluka donijetih u prošlosti je razumijevanje načina na koji ljudi donose odluke. U tu su svrhu ekspertni sustavi vrlo koristan alat. U osnovi programske podrške za ekspertne sustave je emulacija postupaka eksperata u određenim slučajevima. Dakle, dedukcija motiva i percepcija koji su bili prisutni u donošenju odluka iz prošlosti je

konzistentna s pristupom odlučivanju pomoću ekspertnih sustava u svrhu istraživanja principa djelotvornog odlučivanja.

### 3. PROGRAMSKA PODRŠKA ZA SIMULACIJU KAO PODRŠKA ODLUČIVANJU

Upotreba simulacija u odlučivanju ide ka građenju specijalne vrste programske podrške u koju su uključeni ekspertni sustavi i umjetna inteligencija. Grafička animacija je važan dio tog procesa.

Grafička animacija u simulacijama približava simulacije donosiocima odluka. Grafičke prikaze je lakše interpretirati nego brojeve, a na donosioca odluka imaju i veći utjecaj od riječi. Animacija uz pomoć kompjutorske grafike omogućuje kreiranje "filma" kojim se simulira promatrani sustav uz mogućnost prikazivanja promjena uzrokovanih stanjima sustava.

Programska podrška za ekspertne sustave varira ovisno o predmetu promatranja. Ideja je izgraditi takvu programsku podršku za pomoć u odlučivanju koja će simulirati rad dobrog donosioca odluka. Te rutine tada mogu upotrebljavati i drugi u skladu sa svojim interesima ili interesima njihovih klijenata.

Između simulacija i ekspertnih sustava postoji velika sličnost. I simulacije i ekspertni sustavi bazirani su na modularnoj reprezentaciji sustava. Također postoji sličnost u upotrebi "uvjetnih događaja" i pravilo "situacija/akcija" kao način reagiranja modela na izazvane promjene ili nastale uvjete.

Kerckhoffs i Vanstenkeste (4) ističu objektno-orijentirani pristup kao najpogodniji način predstavljanja znanja u simulacijskim modelima, a u kojem se mogu polučiti sve tri reprezentacijske sheme: logička, proceduralna i mrežno-orijentirana reprezentacijska shema. Objektno-orijentirani pristup omogućuje ugradnju ljudskog znanja u simulacijske modele na prirodan način. Najznačajnija prednost ovog pristupa je u lakoći razvoja modela i integriranog dizajniranja.

O'Keefe (9) razmatra moguće načine kombiniranja ekspertnih sustava i simulacija. Najočitiiji način njihovog kombiniranja je obuhvaćanje jednog sustava drugim, ali naravno oni mogu biti stukturirani i kao odvojene programske podrške koje komuniciraju u paralelnoj vezi. Drugi način njihova kombiniranja je kooperativni. S ovakvim načinom komuniciranja između simulacija i ekspertnih sustava moguće je obuhvatiti oba sustava sa širim simulacijskim sustavom ili ekspertnim sustavom koji direktno komunicira s donosiocem odluka. To je obično ekspertni sustav koji stoji između programskog paketa i korisnika i generira neophodne instrukcije za vođenje dijaloga te interpretira i objašnjava rezultate dobivene iz programskog paketa.

Tehnike prethodnog procesiranja informacija su nov matematički pristup koji omogućava da simulacije postanu praktičan analitički alat. Upotreba upravljačkih sustava informacijskim bazama u simulacijama otvara mogućnost traženja modela koji optimalno

odgovara korisnikovim željama ili kada se postojeći model rekonstruira. Takve tehnike omogućuju istraživaču da se više usredotoči na istraživanje problema i modeliranje, a manje na probleme izgradnje programske podrške. Najkorisniji aspekt takvog pristupa je analiza alternativa - mogućnost poimanja što nedostaje alternativama rangiranim ispod prvog mjesta da postanu najbolje. Dio takve analize je svakako "što-ako" analiza čiji se odgovori mogu lako dobiti upravo korištenjem inteligentno upravljanim bazama znanja.

Značenje prethodnog procesiranja informacija posebno ističu Kerchoffs and Vansteenkeste: "U području procesiranja informacija fundamentalna tranzicija je počela od procesiranja podataka k procesiranju znanja formiravši ključ za novu generaciju kompjutora".

#### 4. OPTIMALIZACIJA U SIMULACIJSKOM MODELIRANJU

Imajući u vidu ranije diskutirano, sustav za podršku odlučivanju baziran na simulacijskom modeliranju mora sadržavati tri važna dijela:

1. simulacijski blok,
2. optimalizacijski blok i
3. inteligentno upravljan sustav baza podataka.

U tu svrhu simulacijski proces mora biti dekomponiran u slijedeće funkcije: prikupljanje znanja, mjerenje, modeliranje, vrednovanje modela i korištenje modela. Ovaj je pristup baziran na konceptu "kosustava" i "tipa eksperimenta". Kosustav se definira kao dodatni sustav za mjerenje i kontrolu ostvarivanja svrhe modela, te postprocesiranje izmjerenih podataka. Tip eksperimenta determinira granice eksperimenata kako u realnom svijetu, tako i u području simulacijskog eksperimenata. Ovakva dekompozicija omogućuje bolji protok informacija između svih dijelova sustava za podršku odlučivanju.

Jedna od glavnih aktivnosti vezanih za modeliranje i implementaciju modela je upravljanje podacima u simulacijskoj studiji. Informacije se spremaju u informacijski sustav i postaju okvir za donošenje dobrih odluka. Inteligentan upravljački sustav dopušta analitičaru ponavljanje svih koraka eksperimenata za svaku alternativu. Prilikom dizajniranja takvog upravljačkog sustava principi i modeliranja i simulacije moraju biti uzeti u obzir.

Simulacijsko-informacijski sustav mora biti dizajniran tako da a priori uključuje znanje iz realnog svijeta i a posteriori znanje stečeno tijekom simulacijskog eksperimenata (opis modela, vrednovanje podataka, rezultati simulacija...). Bitna podrška tom sustavu je umjetna inteligencija. Njena uloga u modeliranju i simulaciji može biti promatrana preko deskriptivno orijentiranih aplikacija ili preko preskriptivno orijentiranih aplikacija gdje umjetna inteligencija pruža pomoć u sintezi modela.

Optimalizacijski blok može biti izgrađen kao jedan ekspertni sustav koji je povezan sa simulacijskim blokom i bazama znanja. Međusobno mogu biti povezani na kooperativni

način, što znači da će postojati određena preklapanja nekih njihovih dijelova u svrhu razmjene informacija. U isto vrijeme svaki blok mora biti samostalan u radu i mora imati osiguranu komunikaciju s donosiocem odluka.

Preklapanja između optimalizacijskog i simulacijskog bloka odvijaju se preko optimalizacijskih varijabli (primarna validacija). Blokovi izmjenjuju informacije o "kvaliteti" simulacija, ali u isto vrijeme neke se od tih informacija (rezultati optimalizacije simulacijskog ekperimenta) izmjenjuju s bazama znanja. Izbor metode optimalizacije ovisi o karakteristikama simulacijske studije.

Postoji više grupa metoda optimalizacije simulacijskih eksperimenata i komparacije alternativa. Respektirajući stohastičku prirodu simulacija, optimalizacija često ne ide bez statističkih metoda. Kod slučajeva, gdje alternative čine konačan, neuređen skup, vrlo se često koriste upravo statističke metode: analiza varijance, procedure rangiranja i selekcije, tehnike višestruke komparacije i druge.

Kod slučajeva, gdje su varijable za odlučivanje kvantitativne i kontinuirane, alternative mogu činiti beskonačan skup. Svaka točka u tom skupu predstavlja kombinaciju vrijednosti varijabli za odlučivanje i rezultira skupom zavisnih varijabli koje se mogu mjeriti na kontinuiranoj skali tijekom simulacijskog ekperimenta. U biti, cilj simulacijske analize postaje sve bliži cilju optimalizacije. Safizadeh (12) ističe važnost eksperimentalnog dizajna u simulaciji, aplikaciji matematičkog programiranja u simulaciji jednostrukog ili višestrukog odaziva, metodi površine odaziva, perturbacijske analize i analize u domeni frekvencija.

Tehnike matematičkog programiranja su poznate u optimalizaciji. Također postoji mnogo kompjuterskih aplikacija koje podržavaju ovakav tip optimalizacije. U procesu optimalizacije simulacijskog procesa primjena matematičkog programiranja može se klasificirati u dvije grupe: 1. jednokriterijalna optimalizacija (tehnike direktnog pretraživanja, gradijentne tehnike), i 2. višekriterijalna optimalizacija (tehnike na grafovima, ciljno programiranje, tehnike omeđene i neomeđene optimalizacije,..).

Za vrijeme odvijanja simulacijskog ekperimenta mogu se dogoditi značajne promjene (promjene u ciljevima, alternativama ili odnosima između njih). Ovakve promjene zahtijevaju remodeliranje i postprocesiranje u simulacijskom bloku. Također, ove promjene mogu izazvati i izmjene optimalizacijskih varijabli, pa čak i metodu optimalizacije. A sve to ovisi o cilju koji donosilac odluke želi postići studijom (sekundarna optimalizacija). Prema tome, čitav proces mora ići preko informacijski baziranog upravljačkog sustava.

Respektirajući promjene, koje mogu nastati, uputno je sve blokove sustava za podršku odlučivanju uključiti u veći ekspertni sustav koji će omogućiti djelotvornu komunikaciju između blokova i između korisnika i blokova. Stoga su komunikacije bitne za funkcioniranje čitavog sustava. Inteligentni upravljački sustav omogućuje spremanje i procesiranje informacija iz svih eksperimenata i njihovu optimalizaciju, te izbor pravilnog smjera odvijanja simulacijskih eksperimenata.

## 5. ZAKLJUČAK

Simulacije se često koriste kao podrška u procesu donošenja odluka. Istraživanja pokazuju da je upotreba simulacija u porastu u proizvodno/procesnim funkcijama poduzeća i marketingu, dok je u opadanju u financijama. U isto vrijeme simulacije se sve više koriste u javnim službama prilikom rješavanja različitih socijalnih problema.

U današnje vrijeme upotreba simulacija u upravljanju ide prema izgradnji specijalne vrste programske podrške - ekspertnih sustava i sustava za prethodno procesiranje informacija uz korištenje umjetne inteligencije i grafičke animacije. Postoji niz sličnosti između ekspertnih sustava, umjetne inteligencije i simulacija, pa je prirodno da kombinacija ovih tehnika dovodi do dobrih odluka.

Važan pristup u donošenju dobrih odluka je optimalizacija simulacijskih eksperimenata. Između ostalih metoda u ovom području, moguća je primjena i matematičkog programiranja i njihovo ugrađivanje u ekspertni sustav kao dio sustava za podršku odlučivanju baziranog na simulaciji.

Sustav za podršku odlučivanju baziran na simulaciji mora sadržavati simulacijski blok za provođenje simulacijskih eksperimenata, optimalizacijski blok za traženje optimalnih rješenja i inteligentan informacijski upravljački sustav koji donosiocu odluka pruža sve moguće informacije o simulacijskom eksperimentu i njegovoj optimalizaciji. Informacijski sustav mora biti dizajniran tako da a priori obuhvaća znanje iz realnog svijeta i a posteriori znanje koje je rezultat provođenja simulacijskih eksperimenata i njihove optimalizacije. Takav sustav pohranjuje i upravlja svim informacijama o eksperimentima i omogućuje izbor pravilnog smjera za daljnja istraživanja.

### LITERATURA:

1. **Cox, J.F., Ledbetter, W.N., and Smith, J.M.**, *Simulation as an Aid to Corporate Decision-Making*, Simulation, 29 (1977) no 3.
2. **Cooley, R.E., and El-Hadad, K.**, *Dragoman: an expert system to aid users of a simulation model*, Simulation 57:2 (1991), 11-113.
3. **Henz-Luermann, M.A., Byrnett, D.L.**, *A pilot study of the impact of animation on decision-making*, Simulation, October 1989, 153-158.
4. **Kerckhoffs, E.J.H., and Vansteenkiste, G.C.**, *The impact of advanced information processing on simulation - An illustrative review*, Simulation 46:1 (1986), 17-26.
5. **Nagel, S.S.**, *Simulating past decision-making to deduce motives and perceptions*, Simulation, June 1989, 222-223.
6. **Nagel S.S., and Bienvenue L.**, *Simulation to aid in influencing decision-makers*, Simulation, August 1989, 76-77.

7. **Nagel, S.S., and Prevo, J.**, *Simulating bilateral decision- making to facilitate settlements*, Simulation, October 1989., 177-180.
8. **Nelson, F.F., Bradbard, D.A., Cox, J.F., and Ledbetter, W.N.**, *Simulation in corporate decision making: Then and now*, Simulation, 49:6 (1987), 272-282.
9. **O'Keefe, R.**, *Simulation and expert systems - A taxonomy and some examples*, Simulation 46:1 (1986), 10-16.
10. **Pidd, M.**, *Computer Simulation in Management Science*, J. Wiley, Chichester, 2-nd edition, 1988.
11. **Rhinehart, R.F.**, *Treats to the growth of operations research in business and industry*, Operations Research, 2 (1954), 229- 233.
12. **Safizadeh, M.H.**, *Optimisation in simulation: Current Issues and the Future Outlook*, Naval Research Logistic, 37:6 (1990), 807-826.
13. **Shannon, R.E.**, *Simulation: A Survey with Research Suggestions*, AIIE Transactions 7, no 3 (1975):289-301.
14. **White, D.J.**, *Operational Research*, J. Wiley, Chichester, 1985.