Scenarijski simulacijski model za optimalnu alokaciju građevinskih strojeva

Galić, Mario; Završki, Ivica; Dolaček-Alduk, Zlata

Source / Izvornik: **Građevinar, 2016, 68, 105 - 112**

Journal article, Published version
Rad u časopisu, Objavljena verzija rada (izdavačev PDF)

https://doi.org/10.14256/JCE.1462.2015

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:133:996417

Rights / Prava: Attribution 4.0 International/Imenovanje 4.0 međunarodna

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

GRAĐEVINSKI I ARHITEKTONSKI FAKULTET OSIJEK
Faculty of Civil Engineering and Architecture Osijek

Repository / Repozitorij:

Repository GrAFOS - Repository of Faculty of Civil Engineering and Architecture Osijek

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

Primljen / Received: 14.9.2015.
Ispravljen / Corrected: 11.1.2016.
Prihvaćen / Accepted: 22.1.2016.
Dostupno online / Available online: 10.3.2016.

Scenarijski simulacijski model za optimalnu alokaciju građevinskih strojeva

Autori:



Mario Galić, dipl.ing.građ.
Sveučilište Josipa Jurja Strossmayera u Osijeku
Građevinski fakultet
Zavod za organizaciju, tehn. i menadžment
mgalic@gfos.hr



Prof.dr.sc. Ivica Završki, dipl.ing.građ.
Sveučilište u Zagrebu
Građevinski fakultet
Zavod za organizaciju i ekonomiku građenja
zavrski@grad.hr



Izv.prof.dr.sc. Zlata Dolaček-Alduk, dipl.ing.građ.
Sveučilište Josipa Jurja Strossmayera u Osijeku
Građevinski fakultet Osijek
Zavod za organizaciju, tehn. i menadžment
zlatad@gfos.hr

Prethodno priopćenje

Mario Galić, Ivica Završki, Zlata Dolaček-Alduk

Scenarijski simulacijski model za optimalnu alokaciju građevinskih strojeva

Metode optimizacije imaju veliku važnost pri sužavanju izbora resursa na konačni i pri alokaciji resursa u svim fazama projekata. To se naročito odnosi na složena projektna okruženja gdje je potrebno provesti alokaciju resursa (strojeva) na više građevinskih projekata u njihovim raznim fazama i prioritetima. U radu se predlaže model koji se zasniva na algoritmu višekriterijske optimizacije i rangiranja scenarija suboptimalnih programa serijskog višekanalnog rada građevinskih strojeva pri konačnom broju strojeva za izbor, te izlučivanje presjeka optimalnih programa i/ili scenarija programa u složenom okruženju.

Ključne riječi:
alokacija, binarni program, građevinski strojevi, optimizacija, redovi čekanja, scenariji

Preliminary note

Mario Galić, Ivica Završki, Zlata Dolaček-Alduk

Scenario simulation model for optimized allocation of construction machinery

Optimization methods for narrowing down the choice of resources, and for their allocation, are highly important in all phases of construction projects. This particularly concerns complex project environments where resources (construction machines) have to be allocated to several construction projects at different phases and with different priorities. The authors propose a model based on the multi-criteria optimisation algorithm and the ranking of scenarios involving sub-optimal programs for serial multi-channel operation of construction machines, with a fixed number of machines for final selection, and with separation of the optimum program and/or program scenario cross-sections in complex environment.

Key words:
allocation, binary program, construction machinery, optimization, queues, scenarios

Vorherige Mitteilung

Mario Galić, Ivica Završki, Zlata Dolaček-Alduk

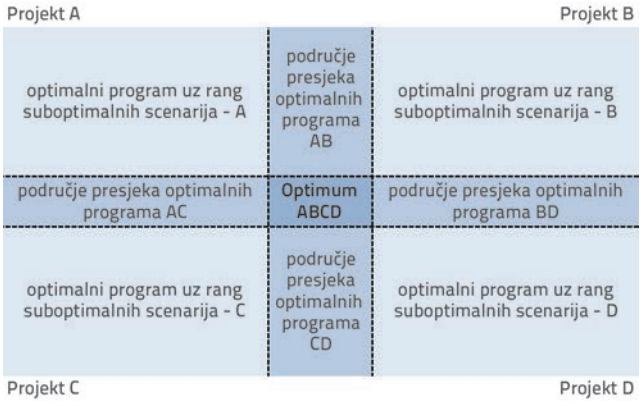
Szenariobasiertes Simulationsmodell zur optimalen Allokation von Baumaschinen

Optimierungsmethoden spielen bei der engeren Auswahl von Ressourcen, die zu finalen Entscheidungen führt, sowie bei der Allokation in allen Phasen des Projekts eine wichtige Rolle. Insbesondere gilt dies im komplexen Projektumfeld, das eine Allokation von Ressourcen (der Baumaschinen) auf verschiedenen Bauprojekten in unterschiedlichen Phasen und mit unterschiedlichen Prioritäten verlangt. In dieser Arbeit wird ein Modell vorgeschlagen, dass auf dem Algorithmus der Mehrkriterienoptimierung und der Rangierung von Szenarien suboptimaler Programme des mehrkanaliger Serienbetriebs von Baumaschinen bei der finalen verfügbaren Anzahl beruht, sowie die Ausscheidung des Satzes optimaler Programme und/oder Programmszenarien im komplexen Umfeld dargestellt.

Schlüsselwörter:
Allokation, Binärprogramm, Baumaschinen, Optimierung, Warteschlangen, Szenarien

1. Uvod

Odluka ili sužavanje širega na uži te konačni izbor strojeva za angažman na određenim građevinskim radovima svakodnevni je problem koji moraju rješavati inženjeri na gradilištu, ali i menadžment građevinskih tvrtki [1]. Dinamičnost i stohastičko okruženje građevinskih projekata otežavaju i kompliciraju proces odluke. Kompleksnost je naročito izražena u situacijama kada je potrebno ponuditi alokaciju strojeva istovremenim projektima koji su u različitim fazama. U takvim se slučajevima često oslanja na iskustvo inženjera, no odgovornost koja slijedi takvom načinu odlučivanja također često bude predmet naknadne rasprave. Kvantitativna potvrda odluke pruža bolji uvid u rješavanje problema odnosno donošenje odluke u situacijama kada rješenje nije očito, tj. kada se iskustvom i intuitivnošću ne može razlučiti između više varijanti [2, 3]. Metoda modeliranja i simulacije u takvim je situacijama logičan izbor. No, optimizacija pojedinačnih sistema (projekata) ne može ponuditi konačno optimalno rješenje cjelovitog problema (svih projekata koji se razmatraju) [4]. Potrebno je uzeti u obzir međusobne ograničavajuće veze među projektima koji se razmatraju. Također, pri optimizaciji potrebno je osim optimalnog programa zabilježiti i sve suboptimalne programe (scenarije). Scenarije treba rangirati prema usvojenim kriterijima (funkcijama ciljeva optimizacije) kako bi se tijekom bilo koje promjene pri odabranome programu unaprijed znala alternativa. Ovakvim načinom planiranja uzima se u obzir i rizik otkazivanja odabranog programa i omogućava se prilagodljivost pojedinačnih programa, ali i cjelokupnog sustava. Područja suboptimalnih programa (presjek) pojedinih projekata, kao i preklapanje suboptimalnih programa svih projekata, označavaju područje za analizu pri odabiru konačnog programa (slika 1.).



Slika 1. Shematski prikaz optimalnog programa u višeprojektnom okruženju

U ovome se radu razmatra metodologija za odabir građevinskih strojeva za višekanalni, višefazni (serijski) rad u višeprojektnom okruženju. Uzimajući u obzir prethodno spomenute pretpostavke, razvijen je model optimizacije. Model je baziran na dvije uobičajene metode optimizacije u području operacijskog istraživanja, te dvije funkcije cilja optimizacije jednakog prioriteta:

1. binarni linearni program uz zapis svih kombinacija (scenarija) – funkcija cilja minimalni ukupni troškovi rada strojeva po jedinici vremena,
2. teoriju opsluživanja (redova čekanja) – funkcija cilja maksimalni faktor iskorištenja rada najskupljeg stroja u nizu.

Cilj istraživanja je postavljanje modela za rješavanje problema izbora strojeva iz konačnog (određenog) skupa za optimalnu alokaciju na istovremenim projektima, uz rangiranje suboptimalnih scenarija za kvantitativno objašnjenje odabira te za osiguranje pravodobne odluke zbog mogućega zakazivanja odabranog programa zadržavajući kvantitativno dokazanu odluku. Pronalazak područja presjeka optimalnih i suboptimalnih programa ili potvrditi da ne postoji presjek koji obuhvaća sve aktivne srodne projekte u portfelju jest primarni zahtjev koji model treba ispuniti. Također se zahtijeva da je model primjenjiv na različitim serijskim (cikličkim) radovima građevinskih strojeva te da je prilagodljiv s obzirom na izmjene u okruženjima projekata.

2. Metode optimizacije za konačni izbor strojeva

U svom istraživanju autori Rogalska i ostali [5] izradili su i koristili algoritam (eng. *Time Coupling Method* - TCM III) kombinirajući teoriju ograničenja, metodu kritičnog lanca s metodom kritičnog puta za analizu odnosa ukupnog trajanja i troškova projekta. Spomenuti model je potvrđen na slučajevima minimiziranja troškova radnika te za utvrđivanje ukupnih povećanja troškova u realizaciji projekata uz preporuku za daljnje poboljšanje modela kroz primjenu na sličnim problemima. Ovo je jedan od primjera kombiniranja metoda za višekriterijsku optimizaciju u građevinskim projektima. Razna strukturna ograničenja, kao i odnosi funkcija ciljeva, glavni su pokretači i motivacija izrade i modificiranja algoritama za optimizaciju. Prostorno ograničenje gradilišta karakterističan je rubni uvjet za izbor strojeva, što su u svom radu elaborirali autori Jang i ostali [6]. Pri rješavanju alokacije resursa u repetitivnim planovima (cikličkim), tj. modelu minimiziranja ukupnog trajanja projekata uz smanjenje prekida rada, prethodna su istraživanja naglasila bitnost zapisa evolucije optimizacije - skupa suboptimalnih rješenja kao alternative optimalnom programu [7-9].

Linearno programiranje, kao najčešće primjenjivana metoda optimizacije operacijskih istraživanja u inženjerskim strukama, određeno je modelima problema s linearnim ciljem i strukturnim ograničenjima [10]. Oblik varijabli optimizacije razdvajaju linearno programiranje na cjelobrojno i necjelobrojno, te njihovu kombinaciju mješovitog linearnog programiranja [11]. No, u domeni cjelobrojnog linearnog programiranja postoji i binarno linearno programiranje koje služi za optimizaciju raznih problema uključivanjem i isključivanjem slučajeva (0 i 1). Dakle, u binarnom linearnom programiranju varijable su

kombinacije slučajeva programa. Autori Mansini i ostali [12] u pregledu dvadesetogodišnje primjene linearnog programiranja za optimizaciju portfelja zaključili su da:
- varijable ključne za donošenje odluke treba izraziti u odnosu na funkciju cilja,
- stvarni ulazni podaci impliciraju primjenu cjelobrojnog i binarnog linearnog programa uz nužno pojednostavljenje računalnog rješavanja takvih problema.

Za rješavanje malih do srednje složenih projekata autori Son i ostali [13] izradili su hibridni model cjelobrojnog linearnog programa za optimizaciju koji je pogodan za optimizaciju diskretnih i kvazi-kontinuiranih procesa s konačnim rješenjem za planiranje radova. Također su se osvrnuli na nužnost osiguranja pojednostavljenog unosa i kontroliranja modela koji uzima u obzir projektna okruženja u građevinarstvu. Bertsimas i Georghiou [14] razvili su matematički (teoretski) model koji binarni proces donošenja odluke preslikava u konačni mješoviti linearni program u okruženju, gdje se problem povećava s povećavanjem obujma ulaznih parametara. Povećanje i konkretizacija ulaznih parametara s realizacijom projekata karakteristična je za građevinske projekte, no spomenuti model nije razumljiv i potrebno ga je modificirati primjenom na građevinskim projektima. Linearnost modela teoretski je pristup kojim se pojednostavljuje problem i simulacija, no pri planiranju i optimizaciji u građevinskim projektima vrlo je rijetka pojava. To su autori [15, 16] obrazložili te primijenili nelinearni model za optimizaciju troškova u planovima, što olakšava donošenje odluka u fazi prije ugovaranja.
U pregledu dostignuća i preporuka istraživača pri optimizaciji zahtjevnih problema, autori Gabrel i ostali [17] zaključili su sljedeće:
- treba precizno razlikovati dva tipa osjetljivosti modela: izvodljivost rješenja i opasnost od suboptimalnosti rješenja,
- za višekriterijsku optimizaciju zahtjevnih problema najpogodnije je primjenjivati evolucijske algoritme,
- stohastičko okruženje zahtjevnih problema izraženo je u izmjenama ulaznih parametara, uz konstantnu analizu odnosa svih funkcija ciljeva [18, 19].

Optimizacija serijskog rada općenito je u literaturi zastupljena u domeni teorije redova čekanja (opsluživanja). Prema literaturi, red čekanja definira linearnim (rijetko nelinearnim) programom jedne ili više faza i kanala opslužujući veći broj klijenata u dolasku koji je u kraćim intervalima nego što traje obrada, te se stoga stvara red čekanja [10, 20-23]. U građevinarstvu redovi čekanja su svakodnevni inženjerski problem koji u svojim jednostavnijim oblicima (npr. jednokanalni jednofazni sustav) ne zahtijevaju gotovo nikakvu kvantitativnu potvrdu već su predmet direktne inženjerske odluke. No, pri povećavanju broja kanala i povećavanjem broja faza (ili strojeva) te pri istodobnoj potražnji više lokacija (gradilišta) za istim strojevima, ovaj problem postaje kompleksan i vrlo rizičan za samostalnu nekvantitativno potvrđenu odluku inženjera. U takvim slučajevima modeliranje i simulacija postaju logičan alat pri olakšavanju i kvantitativnoj potvrdi odluke [24-26]. U građevinskim projektima otvoreni tipovi redova s beskonačnim brojem ulaza u sustav nisu česti. Sustavi s određenim (zatvoreni) brojem klijenata na ulazu (M/M/k tipovi redova) u sustav karakteristični su, kao i disciplina reda *first in – first out* (FIFO). Autori Terekhov i ostali [27] izradili su model koji kombinira metodu redova čekanja s planiranjem radova dvaju strojeva u alternaciji, te su dokazali kako kombinacija metoda planiranja s metodom redova čekanja pruža novu dimenziju u dinamičkom upravljanju projektima. No, za zahtjevne sustave u višeprojektnom okruženju, taj model ne pruža evolucijski pregled optimizacije. S obzirom na konstantan porast cijena goriva, autori Stein i ostali [28] primijenili su teoriju redova opsluživanja u modificiranom obliku, gdje su ukupnu potrošnju goriva postavili kao funkciju cilja optimizacije svih ostalih procesa (gradilišta, transporta, itd.). Model i algoritam za optimizaciju izbora strojeva/radnika, uz jednu funkciju cilja, a to su minimalni troškovi najma, postavili su i testirali simulacijom događaja autori Sharma i ostali [29]. Njihov model je potvrđen pri spomenutom jednom kriteriju optimizacije i pri jednom projektu, bez zapisa suboptimalnih programa koji bi poslužili za post-optimalnu analizu odabira u fazi realizacije projekta.
Metoda neuralnih mreža zadnjih je desetak godina jedna od najpopularnijih metoda pri simulaciji slučajeva u raznim inženjerskim strukama. U građevinarstvu je najčešća kao alternativa i dopuna metodi Monte Carlo pri simulaciji događaja, uglavnom u planiranju i upravljanju troškovima i ostalim resursima u projektima [30-35]. Autori Hola i Schabowicz [36] izradili su model neuralne mreže za određivanje trajanja i cijene serijskog rada strojeva na iskopu, zaključivši da je i ta metoda primjenjiva uz proširivanje kriterija za odabir strojeva. Slično zaključuju i autori [37], no uzimajući u obzir drugačiji spektar kriterija za optimizaciju. Glavna zamjerka ili nedostatak neuralnih mreža koju su razni autori istaknuli, a autori Kim i ostali saželi u svom radu [38], jest nejasnost evolucije optimizacije i odluke, kao i dugotrajnost povratne informacije zbog dugotrajnog unosa (treniranje neuralne mreže) ulaznih parametara.
Prema pregledu dostignuća i preporuka znanstvenika u područjima koja su autori izdvojili kao relevantna za izradu svog modela, jasne su pretpostavke i zahtjevi koji se postavljaju u vezi s tim modelom:
a) model treba biti primjenjiv za rješavanje problema bez obzira na zahtjevnost problema,
b) zapis scenarija treba biti evolucijski zapis optimizacije zbog izlučivanja presjeka programa u projektnom okruženju, kao i za postoptimalnu analizu u fazi realizacije projekata,
c) višekriterijska optimizacija zahtijeva kontinuiranu kontrolu odnosa funkcije ciljeva (kriterija) tijekom realizacije projekata,
d) unos i kontrola ulaznih parametara trebaju biti jednostavni, kao i slanje (izvoz) rezultata radi moguće daljnje obrade za donošenje odluke o konačnom izboru.

3. Model za višekriterijsku optimizaciju višekanalnog serijskog rada strojeva

3.1. Formulacija problema

U slučaju kada je potrebno izraditi plan alokacije strojeva na sličnim istovremenim radovima (višekanalni serijski rad) u različitim projektima, ili na istom projektu samo za različite lokacije, iz konačnog skupa strojeva (za uži izbor strojeva – "pool"), te ako je skup strojeva znatno veći od broja lokacija na koje ih se mora rasporediti i ako su njihove karakteristike slične (učinci i jedinične cijene), broj kombinacija mogućih scenarija prelazi ljudsku maštu i iskustvo. Tada modeliranje i simulacija postaju pogodan alat za donošenje odluke. Autori u ovome radu predlažu model i algoritam za optimizaciju za upravo za takav problem: ukupno projektno okruženje uz evolucijski zapis višekriterijske optimizacije.

3.2. Grafički prikaz i koncept modela

Ulaz u sustav (slika 2.) jest baza raspoloživih strojeva za izvršenje radova u istovremenim projektima. Za svaki projekt u prvom stupnju optimizacije izradi se dvokriterijska optimizacija (dvije funkcije ciljeva): minimalni ukupni troškovi serijskog rada strojeva u jedinici vremena i maksimalni faktor iskorištenosti najskupljega stroja. Optimizacija se provodi pomoću binarnog linearnog programa pri kojem su kombinacije angažiranih strojeva u seriji varijable binarnog tipa (0-nije angažiran; 1-stroj je angažiran) uz zapis svih scenarija prema oba kriterija. Izlazni podaci optimizacije su optimalni program i rangirani scenariji. Prikupljanjem optimalnih programa i rangiranih scenarija projekata kreira se skup scenarija programa projektnog okruženja. Tada pred spomenutim skupom stoji prvo ključno pitanje:

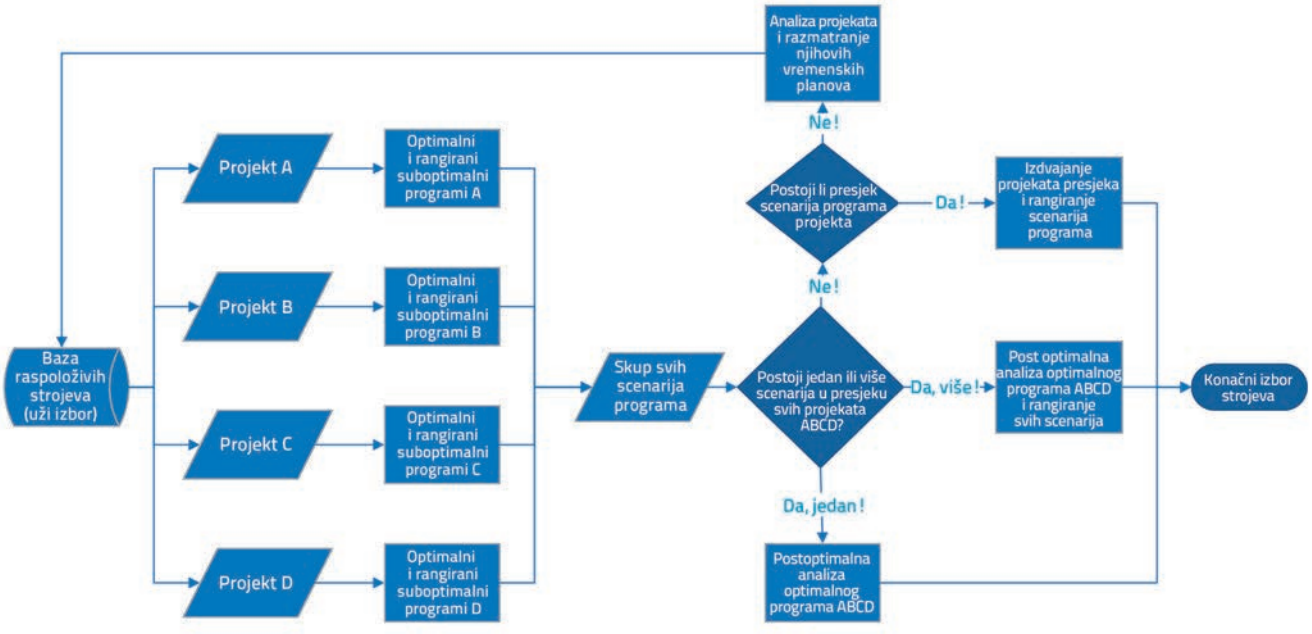
Postoji li jedan ili više programa iz skupa koji zadovoljava presjek svih projekata u okruženju?

Ako postoji jedan takav program, tada slijedi postoptimalna analiza programa (analiza osjetljivosti programa) i konačni izbor strojeva. Postoji li više takvih programa, tada je, prije konačnog izbora, potrebno izraditi njihov rang prema spomenutim kriterijima. Ako ne postoji niti jedan program koji zadovoljava presjek svih projekata, tada slijedi drugo ključno pitanje:

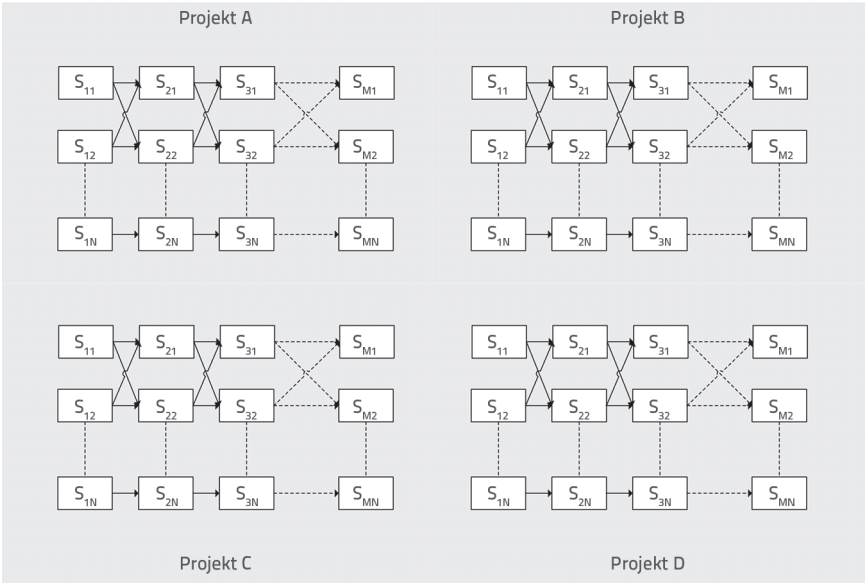
Postoji li program koji zadovoljava presjek projekata, ali ne svih u okruženju?

Ako postoji, tada takav program analiziramo u sljedećem koraku i izdvajamo projekte koji su u presjeku. Za projekte za koje postoji takav program radimo rang i konačni izbor, a projekte koji nisu u presjeku analiziramo kroz njihove ulazne podatke, te se po mogućnosti može provesti analiza prioriteta kriterija i izvršiti konačni izbor prema samo jednom od kriterija (vremenski plan, varijantna rješenja, itd.).

Na slici 3. prikazan je višekanalni višefazni (serijski) model rada građevinskih strojeva (označeni slovom "S"), gdje je "m" broj faza ili različitih strojeva u lancu, broj "n" je broj kanala u više-projektnom okruženju. Punim strelicama je naznačena disciplina reda opsluživanja, gdje je prvi slobodni stroj prvi izbor (FIFO disciplina reda), a isprekidane strelice prikazuju konačnost serije i kanala. U ovoj se fazi optimizacija provodi za svaki projekt kao da je izdvojen iz okruženja, tj. da ne postoje međusobno ograničavajući odnosi između projekata.



Slika 2. Karta procesa konačnog izbora pri višekriterijskoj optimizaciji u složenom projektnom okruženju



Slika 3. Grafički prikaz višekanalnog višefaznog serijskog rada u složenom okruženju

3.3. Matematički prikaz modela

Broj projekata za koje je potrebno izvršiti alokaciju strojeva kreće se od 2 do "α", a ukupni broj kombinacija scenarija programa u jednom projektu označen je sa "K^{α}" i o planiranom ili određenom broju strojeva (faza) u seriji "m", a dan je izrazom za broj varijacija bez ponavljanja, izraz (1):

$$K^{\alpha}(n) = \binom{n}{m} m! \tag{1}$$

$\alpha > 1$; m = 1, 2, 3, ... M; n = 1, 2, 3, ... N

U skupu svih kombinacija tražimo optimalni program i rangiramo ostale kombinacije programa prema funkcijama ciljeva: ukupni troškovi rada strojeva po jedinici vremena (optimalni program "minC" u izrazu (2)) i faktor iskorištenosti najskupljih servera (stroja) u seriji (optimalni program "maxρ" u izrazu (3) prema općem izrazu teorije redova čekanja za iskorištenost servera - omjer prosječnog broja ulazaka u sustav "λ" i prosječnog broja opsluživanja u određenom vremenu "μ"), te gdje su varijable "S_{mn}" binarne [0;1]:

$$\min C = \sum_{m}^{M} \sum_{n}^{N} S_{mn} * c_{mn}; \quad S_{mn} \in [0;1] \tag{2}$$

$$\max \rho_{Smn \rightarrow cmax} = \frac{\lambda}{\mu_{Smn \rightarrow cmax}} \tag{3}$$

Za svaki projekt u skupu (okruženju) [2→α] potrebno je izvršiti spomenutu dvokriterijsku optimizaciju i rangirati sve programe u scenariju. Nakon toga traži se presjek programa svih projekata gdje se traže oni programi koji će uključiti, ako ne sve projekte u projektnom okruženju, tada najveći broj projekata i radi se konačni rang scenarija alokacije strojeva na projekte. Optimalni program je onaj koji istovremeno ispunjava oba kriterija u svojim smjerovima (minimalni ukupni troškovi i maksimalna iskorištenost najskupljega stroja).

3.4. Simulacijski model

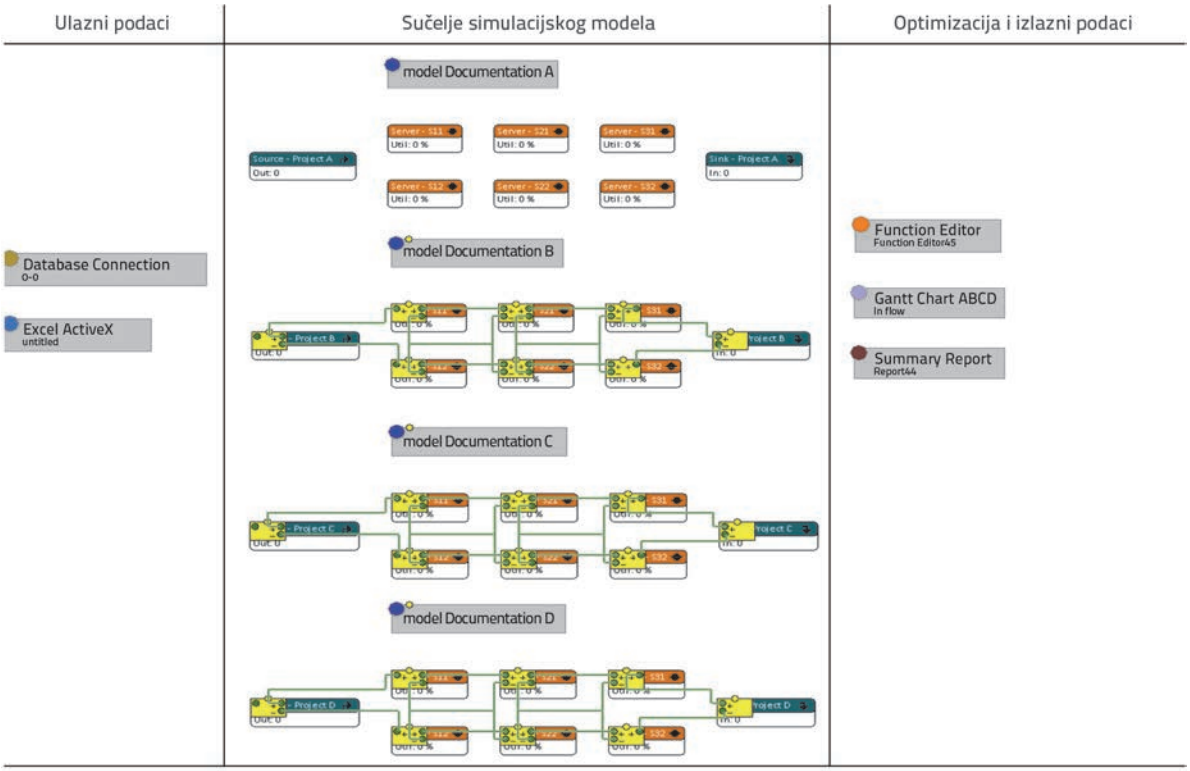
Na osnovi matematičkog modela izrađen je simulacijski model u računalnom programu Enterprise Dynamics software (slika 4.). Taj računalni program pokazao se uspješnim u simulaciji diskretnih procesa u građevinskoj industriji [24, 39], a zasniva se na 4DScript programskom jeziku. Model je strukturiran u tri dijela: ulazni podaci, sučelje modela i izlazni podaci.

Ulazni podaci – sadržavaju baze podataka raspoloživih strojeva s pripadajućim podacima o strojevima (Database Connection), te poveznicu s poznatim podacima o gradilištima uz poveznicu na internetske karte radi pridruživanja globalnih koordinata (*Excel ActiveX*). Ovakav pristup modeliranju ulaznih podataka nudi povezivanje na već uređene (postojeće) baze podataka ili bazama podataka u serverskom načinu rada (dinamičnom okruženju). Spomenutim entitetima (*Database conncetion* i *Excel ActiveX*) radi se premosnica između vanjskih ulaznih podataka i modela.

Sučelje simulacijskog modela – model se sastoji od svih projekata u okruženju višekanalnog serijskog rada s definiranim kanalima i disciplinom redova uz pripadajuće dodatne podatke o svakom projektu kojima se definiraju uvjeti korištenja strojeva iz baze (u modelu entitet "*model Documentation*"), te poveznice za praćenje modela u tijeku simulacije. Svaki projekt je definiran ulazom u kanale, tj. frekvencijom ulaza što je u modelu entitet *Source* (to je ustvari "λ" iz izraza (3)) koji je FIFO vezom povezan sa serijom servera, kao i njihovi međusobni odnosi, a koji su određeni distribucijom vremena opsluživanja ("μ" u izrazu (3)); te izlazom označenim s entitetom *Sink* koji je povezan s entitetom *Export table* čime se izvoze pojedinačni rezultati simulacije.

Optimizacija i izlazni podaci – za dvokriterijsku optimizaciju definiranu matematičkim modelom pridodan je entitet (*Function Editor*), točnije "atom" u ovom računalnom programu, u kojem su definirane funkcije ciljeva i ograničenja optimizacije, zatim kao dodatni izlazni podatak pridružen je ispis plana u obliku gantograma projektnog okruženja (*Gant Chart ABCD*), te rangirani scenariji suboptimalnih rješenja u matričnom obliku (*Summary Report*).

Model u ovakvom obliku spreman je za simulaciju, te se kontrolira isključivo preko dokumenata ulaznih podataka. Sučelje modela služi za definiranje vremena simulacije i pokretanje simulacije. Izlazne podatke moguće je pohraniti u dokument ulaznih podataka radi daljnje obrade i analize tijekom planiranja i realizacije projekata.



Slika 4. Simulacijski model izrađen u računalnom programu Enterprise Dynamics software

4. Rasprava

Dosadašnja iskustva i zaključci istraživača pri rješavanju zahtjevnih problema optimizacije i alokacije resursa pokazali su da metode trebaju težiti jednostavnosti pri unosu ulaznih parametara i kontroli izlaznih podataka, te da je evolucijski zapis optimizacije važan za uzimajući u obzir rizika otkazivanja odabranog programa. Matematički pristup optimizaciji, inženjerskom načinu razmišljanja, služi kao platforma za izradu novih i modifikaciju postojećih metoda optimizacije. Kombinacije dosadašnjih metoda optimizacije treba istražiti i razvrstati ih prema tipovima problema za koje su najprimjerenije. Model izložen u ovome radu pokazao se uspješnim pri rješavanju problema fragmentiranih i asimetričnih baza podataka (ulaznih parametara) u višeprojektnom okruženju. Prema preporukama prijašnjih istraživanja, model uzima u obzir dinamičnost i osjetljivost ulaznih podataka. Prednost je toga modela što povezuje vanjske servere (izvore) podataka kojima tvrtka upravlja sa simulacijskim modelom, te nudi optimizaciju kao kvantitativnu potvrdu razlika među scenarijima. Glavni su nedostaci modela to što treba uložiti relativno veći trud i vrijeme te imati osnovno predznanje programiranja za izradu modela, ali to ovisi u kojoj fazi se radi simulacija i optimizacija. Stoga model izložen u ovome radu treba dalje razvijati kako bi se omogućio još jednostavniji unos ulaznih parametara i postiglo upravljanje rezultatima optimizacije. Višeprojektno okruženje je karakteristično i uobičajeno u poslovanju građevinskih tvrtki, kao i rasprostranjenost gradilišta istog projekta. Autori su model izradili upravo za takav tip problema - za optimizaciju zahtjevnih problema optimizacije i alokacije strojeva. Višekanalni serijski rad strojeva u građevinarstvu karakterističan je za zemljane radove (npr. prilikom širokih iskopa i odvoza materijala pri izgradnji dionica cesta), betonske radove (npr. pri betoniranju velikih površina rasprostranjenih lokacija), asfaltiranja cesta i sl. Uzimajući u obzir utjecaj izmjene izbora tehnologije jedno je od otvorenih pitanja u razvoju informacijskog modeliranja građevinskih projekata (eng. *Building Information Modelling* – BIM). Simulaciju scenarija pri izboru tehnologije treba u što jednostavnijem obliku izraziti kao set ulaznih parametara BIM modelu, što je ujedno i točka u kojoj se presijecaju dva koncepta: BIM i simulacija procesa. Simulacija viševarijantnih rješenja jedno je od glavnih argumenata BIM koncepta da u fazi planiranja, ali i u tijeku realizacije projekta, treba upozoriti na nedostatke ili kritična mjesta u projektima. Izlazni podaci predloženog modela, točnije gantogrami, optimalnog programa i suboptimalnih scenarija postaju ulazni podaci BIM modela. Zajednička karakteristika obaju pristupa jest njihova objektna orijentacija, što i omogućava ovu poveznicu, a generiranje sub-optimalnih scenarija je dodatna vrijednost njihova povezivanja. Rangirani scenariji slučajeva, uz optimalni program koje predloženi model jamči, uvelike će olakšati početno planiranje, ali što je još važnije, ažuriranje planova u fazi realizacije projekata.

5. Zaključak

Predloženi model u fazi je eksperimentalnog ispitivanja i verifikacije gdje se pokazao uspješnim alatom za višekriterijsku optimizaciju za alokaciju građevinskih strojeva na više istovremenih projekata. Model je prilagodljiv izmjenama ulaznih podataka, nudi komparaciju optimalnog i suboptimalnih scenarija programa alokacije strojeva uz pripadajuće izlazne podatke, te je time ispunio glavne očekivane pretpostavke. Zahtjevnost problema ne utječe na primjenjivost modela, evolucijski zapis optimizacije je osiguran, model je otvorenog tipa što osigurava kontrolu nad ulaznim podacima i simulacijom, te spreman je za povezivanje s vanjskim bazama ulaznih podataka. U daljnjem je radu potrebno utvrditi njegovu konzistentnost i prilagodljivost na rješavanju raznih problema sličnog tipa. Model će se ispitati na rješavanju problema alokacije strojeva u višeprojektnom okruženju ili u slučajevima rasprostranjenih lokacija (gradilišta) u istom projektu pri istovremenom serijskom (višefaznom) višekanalnom radu. Također, koncept modela dalje će se razvijati uzimajući u obzir preporuke istraživača kao i trendove razvoja informacijske tehnologije. U daljnjem radu autori će, osim razvoja koncepta, svoje istraživanje usmjeriti i na identificiranje dodatnih pogodnih alata (računalnih programa) koji će ispuniti postavljene zahtjeve za predloženi model.

LITERATURA

[1] Bezak, S., Linarić, Z.: Metodološki pristup proračuna troškova strojnog rada pri gradenju, *Građevinar*, 61 (2009) 1, pp. 23-27.

[2] Kovačec, S., Štrukelj, A., Pšunder, M., Lončarić, R., Pšunder, I.: Izbor optimalne tehnologije građenja, *Građevinar*, 62 (2010) 8, pp. 697-705.

[3] Cheng, M.Y., Roy, A. F.: Evolutionary fuzzy decision model for construction management using support vector machine, *Expert Systems with Applications*, 37 (2010) 8, pp. 6061-6069, http://dx.doi.org/10.1016/j.eswa.2010.02.120

[4] Galić, M., Dolaček-Alduk, Z., Završki, I. *The importance of additional criteria in solving transportation problem.* In: Hajdu M, SKibnievski MM, editors. Creative Construction Conference 2013. Budapest: Diamond Congress, Ltd; pp. 219 - 229.

[5] Rogalska, M., Bożejko, W., Hejducki, Z.: Time/cost optimization using hybrid evolutionary algorithm in construction project scheduling, *Automation in Construction*, 18 (2008) 1, pp. 24-31, http://dx.doi.org/10.1016/j.autcon.2008.04.002

[6] Jang, H., Lee, S., Choi, S.: Optimization of floor-level construction material layout using genetic algorithms, *Automation in Construction*, 16 (2007) 4, pp. 531-545, http://dx.doi.org/10.1016/j.autcon.2006.09.006

[7] Nassar, K.: Evolutionary optimization of resource allocation in repetitive construction schedules, *Journal of Information Technology in Construction*, 10 (2005), pp. 265-273.

[8] Liu, S.S., Wang, C.-J.: Optimizing linear project scheduling with multi-skilled crews, *Automation in Construction*, 24 (2012), pp. 16-23.

[9] Cheng, M.Y., Tran, D.-H.: Opposition-based Multiple Objective Differential Evolution (OMODE) for optimizing work shift schedules, *Automation in Construction*, 55 (2015), pp. 1-14, http://dx.doi.org/10.1016/j.autcon.2015.03.021

[10] Taha, H.A.: *Operations Research: An Introduction, 8th* Pearson Education India, New Jersey, 2007.

[11] Helmling, M., Ruzika, S., Tanatmis, A.: Mathematical programming decoding of binary linear codes: Theory and algorithms, *Information Theory, IEEE Transactions on*, 58 (2012) 7, pp. 4753-4769.

[12] Mansini, R., Ogryczak, W., Speranza, M. G.: Twenty years of linear programming based portfolio optimization, *European Journal of Operational Research*, 234 (2014) 2, pp. 518-535, http://dx.doi.org/10.1016/j.ejor.2013.08.035

[13] Son, J., Hong, T., Lee, S.: A mixed (continuous+ discrete) time-cost trade-off model considering four different relationships with lag time, *KSCE Journal of Civil Engineering*, 17 (2013) 2, pp. 281-291, http://dx.doi.org/10.1007/s12205-013-1506-3

[14] Bertsimas, D., Georghiou, A.: Binary decision dules for multistage adaptive mixed-integer optimization, *Optimization Online*, pp. 2014.

[15] Klanšek, U., Pšunder, M.: Cost optimal project scheduling, *Organizacija*, 41 (2008) 4, pp. 153-158, http://dx.doi.org/10.2478/v10051-008-0017-3

[16] Klanšek, U., Pšunder, M.: Troškovna optimizacija terminskih planova za vodenje projekata, *Ekonomska istraživanja*, 23 (2010) 4, pp. 22-36.

[17] Gabrel, V., Murat, C., Thiele, A.: Recent advances in robust optimization: An overview, *European Journal of Operational Research*, 235 (2014) 3, pp. 471-483, http://dx.doi.org/10.1016/j.ejor.2013.09.036

[18] Agrama, F.A.: Multi-objective genetic optimization of linear construction projects, *HBRC Journal*, 8 (2012) 2, pp. 144-151.

[19] Yang, X.S., Karamanoglu, M., He, X.: Flower pollination algorithm: a novel approach for multiobjective optimization, *Engineering Optimization*, 46 (2014) 9, pp. 1222-1237, http://dx.doi.org/10.1080/0305215X.2013.832237

[20] Harchol-Balter, M.: *Performance Modeling and Design of Computer Systems: Queueing Theory in Action,* Cambridge University Press, 2013.

[21] Barković, D.: *Operacijska istraživanja,* Sveučilište Josipa Jurja Strossmayera u Osijeku, 1997.

[22] Stojiljković, M.M., Vukadinović, S.: *Operaciona istraživanja,* Vojnoizdavački zavod, 1984.

[23] Dobrenić, S.: *Operativno istraživanje,* Fakultet organizacije i informatike, Varaždin, 1978.

[24] Galić, M., Thronicke, R., Schreck, B. M., Feine, I., Bargstädt, H.J.: Process modeling and scenario simulation in construction using Enterprise Dynamics simulation software, *e-GFOS*, 10 (2015) 1, pp. 22-29.

[25] Jajac, N., Bilić, I., Ajduk, A.: Decision support concept to management of construction projects-problem of construction site selection, *Croatian Operational Research Review*, 4 (2013) 1, pp. 235-246.

[26] Jajac, N., Bilic, I., Mladineo, M.: Application of multicriteria methods to planning of investment projects in the field of civil engineering, *Croatian Operational Research Review*, 3 (2012) 1, pp. 113-125.

[27] Terekhov, D., Tran, T.T., Beck, J.C.: *Investigating two-machine dynamic flow shops based on queueing and scheduling*. Proceedings of ICAPS'10 Workshop on Planning and Scheduling Under Uncertainty, 2010.

[28] Stein, G., Fröberg, A., Martinsson, J., Brattberg, B., Filla, R., Unnebäck, J.: *Fuel efficiency in construction equipment-optimize the machine as one system*. 7th AVL International Commercial Powertrain Conference AVL, SAE p. 8.2013.

[29] Sharma, S., Gupta, D., Sharma, S.: *Analysis of Queuing Scheduling Linkage Model to Minimize the Hiring Cost of Machines/Equipments*. 20th International Congress on Modelling and Simulation, Adelaide, Australia p. 78.2013.

[30] Wang, Y.R., Gibson, G.E.: A study of preproject planning and project success using ANNs and regression models, *Automation in Construction*, 19 (2010) 3, pp. 341-346, http://dx.doi.org/10.1016/j.autcon.2009.12.007

[31] Koo, C., Hong, T., Hyun, C., Koo, K.: A CBR-based hybrid model for predicting a construction duration and cost based on project characteristics in multi-family housing projects, *Canadian Journal of Civil Engineering*, 37 (2010) 5, pp. 739-752, http://dx.doi.org/10.1139/L10-007

[32] Al Bazi, A., Dawood, N.: Developing crew allocation system for the precast industry using genetic algorithms, Computer Aided Civil and Infrastructure Engineering, 25 (2010) 8, pp. 581-595, http://dx.doi.org/10.1111/j.1467-8667.2010.00666.x

[33] Cheng, M.Y., Tsai, H.C., Sudjono, E.: Evolutionary fuzzy hybrid neural network for dynamic project success assessment in construction industry, *Automation in Construction*, 21 (2012), pp. 46-51, http://dx.doi.org/10.1016/j.autcon.2011.05.011

[34] Vouk, D., Malus, D., Carević, D.: Neuralne mreže i njihova primjena u vodnom gospodarstvu, *Građevinar*, 63 (2011) 6, pp. 547-554.

[35] Vukomanović, M., Kararić, M.: Model za predviđanje cijene montažne gradnje, *Tehnički vjesnik*, 16 (2009) 3, pp. 39-43.

[36] Hola, B., Schabowicz, K.: Estimation of earthworks execution time cost by means of artificial neural networks, *Automation in Construction*, 19 (2010) 5, pp. 570-579, http://dx.doi.org/10.1016/j.autcon.2010.02.004

[37] Galić, M., Nasir, A.R., Dolaček-Alduk, Z., Bargstädt, H.-J.: Comparative analysis of the machine labor ratio for earth excavation in different economies, *Creative Construction Conference 2014, Prague, Czech Republic*.

[38] Kim, G.H., Shin, J.M., Kim, S., Shin, Y.: Comparison of school building construction costs estimation methods using regression analysis, neural network, and support vector machine, *Journal of Building Construction and Planning Research*, 1 (2013) 1, pp. 1-7, http://dx.doi.org/10.4236/jbcpr.2013.11001

[39] Weber, J.: *Simulation von Logistikprozessen auf Baustellen auf Basis von 3D-CAD Daten*, 2008.