Optimizacija građevinskih procesa – metode, alati i primjena

Venkrbec, Vaclav; Galić, Mario; Klanšek, Uroš

Source / Izvornik: **Građevinar, 2018, 70, 593 - 606**

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

https://doi.org/10.14256/JCE.1719.2016

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:133:185957

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: 7.7.2016.
Ispravljen / Corrected: 24.11.2017.
Prihvaćen / Accepted: 12.4.2018.
Dostupno online / Available online: 10.8.2018.

Optimizacija građevinskih procesa – metode, alati i primjena

Autori:



Václav Venkrbec, dipl.ing.građ.
Tehničko Sveučilište Brno, Češka
Građevinski fakultet
Institut za tehnologiju, mehanizaciju i menadžment u građevinarstvu
venkrbec.v@fce.vutbr.cz



Doc.dr.sc. **Mario Galić**, dipl.ing.građ.
Sveučilište J.J. Strossmayera u Osijeku
Građevinski fakultet Osijek
Zavod za organizaciju, tehnologiju i menadžment
mgalic@gfos.hr



Izv.prof.dr.sc. **Uroš Klanšek**, univ.dipl.gosp.inž.
Sveučilište u Mariboru
Fakultet građevinarstva, prometnog inženjerstva i arhitekture
Katedra za operativno građevinarstvo
Slovenija
uros.klansek@um.si

Pregledni rad

Václav Venkrbec, Mario Galić, Uroš Klanšek

Optimizacija građevinskih procesa – metode, alati i primjena

U radu je dan pregled suvremenih heurističkih tehnika i metoda matematičkog programiranja. Predstavljeni su moderni alati za optimizacijsko modeliranje, izlažu se najčešći problemi optimizacije u građevinarstvu i daje pregled njihovih nedavnih aplikacija. Rad je istaknuo prostor istraživanja na aktivnim modelima optimizacije, koji su podržani BIM-om s namjerom boljeg upravljanja građevinskim procesima. Ubrzani razvoj modela odlučivanja, koji kombiniraju optimizacijske metode i informacijske sustave, jasno se može predvidjeti za blisku budućnost.

Ključne riječi:
BIM, građevinska proizvodnja, modeliranje, optimizacijske metode, optimizacija procesa

Subject review

Václav Venkrbec, Mario Galić, Uroš Klanšek

Construction process optimisation – review of methods, tools and applications

A review of current heuristic techniques and mathematical programming methods is presented in the paper. Modern optimisation modelling tools are presented, common construction optimisation problems are described, and an overview of their recent application is given. It is also stressed that there is ample room for further research on active BIM-based optimisation models, aimed at better management of construction processes. Accelerated development of decision-making models, which combine optimisation methods and information systems, can be clearly predicted for the near future.

Key words:
BIM, construction production, modelling, optimisation methods, process optimisation

Übersichtsarbeit

Václav Venkrbec, Mario Galić, Uroš Klanšek

Optimierung von Bauprozessen – Methoden, Werkzeuge und Anwendung

In der Abhandlung wird eine Übersicht über die modernen heuristischen Techniken und Methoden der mathematischen Programmierung dargelegt. Vorgestellt werden moderne Werkzeuge für die optimierte Modellierung, es werden die häufigsten Probleme der Optimierung im Bauwesen dargelegt und es wird eine Übersicht ihrer aktuellen Anwendungen gegeben. Die Abhandlung betont den Untersuchungsbereich aktiver Modelle der Optimierung, die durch BIM unterstützt werden, mit dem Ziel eines besseren Bauprozessmanagements. Eine beschleunigte Entwicklung der Entscheidungsmodelle, welche die Optimierungsmethode und die Informationssysteme kombinieren, kann für die nahe Zukunft klar vorausgesehen werden.

Schlüsselwörter:
BIM, Bauproduktion, Modellierung, Optimierungsmethode, Optimierungsprozess

1. Uvod

Optimizacija je već dugo prisutna u industrijskoj proizvodnji. No, i danas je optimizacija područje intenzivnih istraživanja diljem svijeta. Ponovno, nakon njenog zapaženog uzleta između 1950. i 1970. godine. Razlozi tome se mogu pronaći u rastućoj svijesti društva o ograničenosti prirodnih resursa, što je ujedno i potaknulo da optimizacija postane važniji kriterij u poslovnom odlučivanju. Dodatna motivacija je dostupnost računalnih programa i paketa te računala i opreme. Stoga se gotovo zaboravljeni matematički modeli revidiraju, proširuju, modificiraju i verificiraju kroz primjenu pri rješavanju aktualnih problema u industrijskoj proizvodnji.

Važnost kvantitativne potvrde u procesu donošenja odluka posebno je istaknuta u modernim trendovima projektnog menadžmenta. Specifičnost upravljanja građevinskim projektima njihovo je stohastičko i dinamično okruženje, unatoč repetitivnim operacijama, gdje optimizacija predstavlja jednu od faza. Točnost te pravodoban protok informacija važni su za optimizaciju građevinskih procesa i stoga je iznimno važno na vrijeme identificirati koja je od dostupnih tehnika najpogodnija za određeni problem ili kombinaciju problema.

Bez obzira na činjenicu da je građevinarstvo oduvijek orijentirano na projekte [1], ali i podložno neučinkovitosti [2], u praksi se polagala samo ograničena pozornost na matematički bazirane pristupe za optimizaciju procesa. Stoga, bolja svijest o suvremenim tehnikama za optimizaciju procesa može biti općenito korisna svim donositeljima odluka u građevinarstvu, a osobito projektnim menadžerima i stručnjacima za pripremu proizvodnje.

Treba spomenuti da se poboljšanje poslovnih procesa u industriji može postići i kroz sustave planiranja resursa poduzeća (eng. *Enterprise Resource Planning* - ERP). Poznati su različiti ERP sustavi za proizvodnju i trgovinu, a neki od njih su podržani racionaliziranim radnim procesima [3] i planovima [4]. Pregledi spomenutog područja se također mogu naći u literaturi [5], a određeni autori npr. [6], predlažu i pristupe za implementaciju ERP u građevinski sektor. Često se utvrđuje, da ERP sustavi mogu biti pogodna sredstva za reinženjering poslovnih procesa i uvođenje IT sustava [4]. Ovaj rad ipak ne nudi pregled stanja integracije i interoperabilnosti između različitih informacijskih sustava, primjerice ERP i informacijskog modeliranja građevina (BIM), jer se u bazama podataka može naći literatura na tu temu, a neka nedavna istraživanja, npr. [7], čak su upozorila na to da još uvijek postoji i velik nedostatak znanja na tom području.

Međutim, BIM se polagano i sigurno implementira u građevinskoj industriji i nužno je pregledati stanje područja optimizacije procesa, budući da se oba koncepta mogu operativno povezati u svrhu poboljšanja poslovnih rezultata. Pregledom literature utvrđeno je da takav pregled još nije bio učinjen. Autori [8] su istaknuli da je BIM evoluirao i da graditeljska zajednica vidi pomak od 3D ili vizualizacijskog aspekta BIM-a do alata za specifične procese rada koji se izravno primjenjuju za rješavanje realnih problema, kao što su provjere instalacija, sekvencioniranje radova, procjene i dr. Dijalog industrije se sada usmjerava na opće pitanje kako optimizirati učinkovito prikupljanje, analize i širenje informacija u stvarnom vremenu kako bi projekti bili uspješniji. Stoga ovaj rad pruža pregled nedavnih dostignuća u navedenim područjima kao i neke spoznaje o potencijalima u području te na taj način otvara mogućnosti za daljnja istraživanja.

S obzirom na raznovrsnost problema i prethodnih pregleda literature o specifičnim metodama za njihovo rješavanje te alatima za modeliranje, autori ovog rada izradili su pregled onih koje se tiču optimizacije proizvodnih procesa u građevinarstvu, a s ciljem da se stručnoj i akademskoj zajednici ponudi aktualni pregled stanja na spomenutim područjima.

2. Optimizacijske metode

Optimizacijskim metodama se može riješiti širok spektar inženjerskih problema. Iako optimizacijski problemi proizlaze iz različitih područja i različitih sustava, oni se mogu općenito formulirati na iznenađujuće sličan način. Općenito se optimizacijski problem može izraziti u sljedećem obliku:

minimizirati $f(\boldsymbol{x})$,
uz ograničenja $\boldsymbol{h}(\boldsymbol{x}) = \mathbf{0}$ i $\boldsymbol{g}(\boldsymbol{x}) \leq \mathbf{0}$

gdje je $f(\boldsymbol{x})$ ciljna funkcija koju je potrebno minimizirati preko vektora varijabli $\boldsymbol{x}$, a gdje $\boldsymbol{h}(\boldsymbol{x}) = \mathbf{0}$ predstavlja ograničenja jednakosti dok $\boldsymbol{g}(\boldsymbol{x}) \leq \mathbf{0}$ ograničenja nejednakosti.

Ciljna funkcija definira kriterij za odabir optimalnog rješenja, a ograničenja određuju granice prostora mogućih rješenja. Valja istaknuti i to da postoji i oblik problema gdje je potrebno maksimizirati ciljnu funkciju. Varijable su najčešće izračunane između donje i gornje granice, $\boldsymbol{x}^{\mathrm{LO}} \leq \boldsymbol{x} \leq \boldsymbol{x}^{\mathrm{UP}}$, a mogu biti kontinuirane, $\boldsymbol{x} \in \mathbf{R}$, gdje $\mathbf{R}$ označava skup realnih brojeva. Varijable mogu biti i cjelobrojne, $\boldsymbol{x} \in \mathbf{Z}$, gdje $\mathbf{Z}$ označava skup cijelih brojeva, ali i binarne $\boldsymbol{x} \in \{0,1\}^m$.

Odabir odgovarajuće metode za rješavanje pojedinog optimizacijskog problema treba provesti pažljivo i uzimajući u obzir nužnost korisnosti konačnog rezultata. Prije odabira metode, optimizacijski problem treba analizirati s gledišta njegovih funkcija, ograničenja i varijabli. Pristupi rješavanju jedno-kriterijskih optimizacijskih problema mogu se ugrubo podijeliti u dvije glavne skupine: heurističke metode i metode matematičkog programiranja.

Heurističkim tehnikama se rješava širok spektar optimizacijskih problema. Najvažnija prednost je da većina spomenutih tehnika konvergira u razumno kratkom vremenu i primjenjive su pri rješavanju problema koji sadrže nediferencijabilne funkcije. Heuristički algoritmi često u konačnici pretrage nude približno optimalno, tj. suboptimalno rješenje. No, heurističke metode su dokazano primjenjive za rješavanje raznih optimizacijskih problema u građevinarstvu, a najčešće korištene su sljedeće: neposredno pretraživanje (eng. direct

search, DS) [9], evolucijske strategije (ES) [10, 11] i genetski algoritmi (GA) [12,13], tabu pretraživanje (TS) [14], simulirano prekaljivanje (SA) [15], neuralne mreže (NN) [16], optimizacija kolonijom mrava (ACO) [17], optimizacija rojem čestica (PSO) [18], diferencijalna evolucija (DE) [19] i harmonijsko pretraživanje (HS) [20]. Nastavci glavnih heurističkih metoda su metaheurističke i hiperheurističke stohastičke tehnike bazirane na biološki inspiriranim algoritmima, između ostalih: optimizacija bakterijskog traganja za hranom (BFO) [21], kukavičja pretraga (CS) [22], umjetna kolonija pčela (ABC) [23], krijesničin algoritam (FA) [24], šišmišev algoritam (BA) [25], algoritam oprašivanja cvijeta (FPA) [26], umjetna optimizacija biljke (APO) [27], algoritam vučjeg pretraživanja (WSA) [28]. Treba napomenuti da su u literaturi prisutne i različite hibridne kombinacije spomenutih tehnika.

Metode matematičkog programiranja su također prepoznate kao koristan optimizacijski alat u građevinarstvu (primjeri podržani bibliografskim podacima bit će predstavljeni u poglavljima četiri i pet). Glavna zajednička prednost metoda matematičkog programiranja je očekivani egzaktni optimalni rezultat, iako proces pretraživanja ponekad može dulje trajati. Sporija konvergencija rezultata je karakteristična pri optimizaciji složenih kombinatornih, diskretnih, nelinearnih i posebno nekonveksnih problema. Općenito, matematičko programiranje podrazumijeva metode linearnog programiranja (eng. *linear programming*, LP), nelinearnog programiranja (eng. *nonlinear programming*, NLP) mješovitog-cjelobrojnog linearnog programiranja (eng. *mixed-integer linear programming*, MILP) i mješovitog-cjelobrojnog nelinearnog programiranja (eng. *mixed-integer nonlinear programming*, MINLP).

LP je razvijeno područje matematičkog programiranja. Tehnike rješavanja LP općenito se mogu primijeniti za razne optimizacijske probleme koji sadržavaju linearne ciljne funkcije i ograničenja s kontinuiranim varijablama. Poznati simpleksni algoritam [29] možda je i najčešće primjenjivana metoda rješavanja problema LP. No, treba naglasiti da se metoda unutarnje točke [30] smatra učinkovitijim alatom za rješavanje opsežnijih problema LP.

U slučajevima kada optimizacijski problem s kontinuiranim varijablama sadrži nelinearnu funkciju, NLP pristup je nužan kako bi se problem riješio. Mnogi se inženjerski problemi mogu svesti u oblik NLP problema s obzirom na činjenicu da je većina realnih problema nelinearna. Najpogodnija metoda za rješavanje NLP problema treba biti odabrana uzimajući u obzir veličinu problema i karakteristike nelinearnosti. Zasad ne postoji standardna metoda koja bi jednako uspješno riješila sve tipove NLP problema. S druge strane, postoje brojni učinkoviti algoritmi između kojih je moguće odabrati pojedini ili više njih za rješavanje NLP problema. Kao najčešće korištene metode za rješavanje NLP problema mogu se izdvojiti generalizirana metoda reduciranog gradijenta [31], proširena Lagrangeova metoda [32, 33] i sukcesivno kvadratno programiranje [34].

MILP predstavlja proširenje pristupa LP. Dok se algoritmima LP mogu riješiti linearni kontinuirani problemi, MILP metode su primjenjive za rješavanje problema s kontinuiranim i diskretnim varijablama. U MILP problemima, diskretne varijable se mogu smatrati cjelobrojnim ili binarnim. Standardna metoda MILP optimizacije je metoda grananja i ograđivanja [35], iako se metoda rezanja ravnina [36], kao i metoda grananja i rezanja [37], mogu uspješno primijeniti u brojnim slučajevima.

Metode MINLP su nužne za diskretne optimizacijske probleme koje u svojoj formulaciji sadržavaju nelinearne uvjete. Iako se vrlo kvalitetna egzaktna rješenja mogu očekivati od metoda MINLP, treba naglasiti da je područje nelinearne (diskretne) optimizacije kompleksno i metode MINLP još uvijek nisu dostigle razinu razvijenosti onih za linearnu (kontinuiranu) optimizaciju. No, postoje brojne učinkovite metode MINLP za rješavanje nelinearnih diskretnih optimizacijskih problema u građevinarstvu, poput Bendersove dekompozicije [38], nelinearne metode grananja i ograđivanja [39], tehnike izvodljivosti [40], sekvencijalnog diskretnog linearnog programiranja [41], proširene metode rezanja ravnina [42], algoritma nadograđene kazne/vanjske aproksimacije/relaksacije jednadžbi [43], metode grananja i reduciranja [44], algoritma mješovite-cjelobrojne alfa metode grananja i ograđivanja [45], hibridnog algoritma [46], i ostalih.

3. Optimizacijski alati za modeliranje

Danas su na tržištu dostupni brojni različiti programi za računalno modeliranje optimizacijskih problema. Za kombinatoričke i opsežne probleme preporučljivo je koristiti algebarske jezike za modeliranje. Primjerice, sintakse algebarskih jezika za modeliranje su često prilagodljive i omogućuju formulaciju optimizacijskih modela u kompaktnoj formi pomoću indeksiranja. Stoga algebarski jezici za modeliranje, poput AIMMS [47], AMPL [48], CAMPS [49], GAMS [50], LINGO [51], LPL [52], MPL [53], OPL [54] i UIMP [55], mogu se primijeniti za kompleksne i jedinstvene probleme uz moguće revizije prije nego se konačni model izradi. Posebno su korisni pri većem broju ograničenja jednakog tipa i uzorka. Algebarski jezici za modeliranje mogu simultano formulirati sva ograničenja istog tipa i varijable svakog tipa. Primjena algebarskih jezika za modeliranje ubrzava brojne aktivnosti upravljanja modelom, poput transformacije podataka u ulazne parametre modela, modifikacije modela, pristupa podataka i analize rezultata modela.

Proračunske tablice su također vrlo popularan alat među korisnicima pri optimizacijskom modeliranju. Microsoftov paket Excel (Microsoft Visual Basic) s dodacima poput Evolvera [56], Solvera [57] ili What'sBest [58], kao i WinQSB [59] se mogu izdvojiti kao računalni programi bazirani na proračunske tablice, a koji se često koriste za modeliranje optimizacijskih problema. Proračunske tablice su korisnicima pristupačan alat koji omogućuje formulaciju optimizacijskog modela u poznatom računalnom okruženju. S druge strane, optimizacijski model izrađen u proračunskim tablicama je manje transparentan od onih koji su formulirani koristeći se algebarskim jezicima za modeliranje. Tablični unos entiteta modela također oduzima

korisniku više vremena, pa je prihvaćeno da su računalni programi orijentirani na proračunske tablice primjenjivi za modeliranje malih i srednje složenih modela s određenim brojem parametara. Također, postoje i specijalizirani samostalni računalni programi kao što su Gurobi [60], TORA [61] i LIONsolver [62] između ostalih.

Interaktivni računalni (programski) jezici za numeričku i simboličku kalkulaciju također su primjenjivi za optimizacijsko modeliranje. Programski paketi poput Mathematica [63] i Matlab [64] se izdvajaju kao često korišteni interaktivni računalni programski jezici za optimizacijsko modeliranje, iako im to nije primarna svrha. Oba spomenuta paketa računalnih programa omogućuju interaktivno okruženje pri strukturiranju podataka, modeliranje i rješavanje optimizacijskog problema, kao i razne prikaze rezultata (ispisi, grafovi, i sl.).

Trenutačno postoje jasni znakovi povećanja interesa korisnika za primjenu internetskih aplikacija za optimizaciju. Jedan od mogućih načina optimizacije koristeći internet jest primjena otvorenih (besplatnih) programa na serveru NEOS [65]. Na tome serveru moguće je pronaći i poveznice na ostale komercijalne računalne programe za optimizaciju, priručnike za korištenje, rezultate testiranja i publikacije novijih istraživanja u području optimizacije, itd.

4. Primjene optimizacije u građevinskim procesima

4.1. Općeniti oblici optimizacijskih problema karakterističnih za građevinske procese

U ovom poglavlju dan je kratak pregled izvora i definicija poznatih optimizacijskih problema koji se mogu prepoznati u građevinskim procesima. Njihov originalni naziv, općeniti opis i ciljevi, kao i originalni izvor, prikazani u tablici 1., poredani su abecednim redom. Optimizacijski problemi podijeljeni su prema njihovoj primarnoj funkciji cilja i formiraju dvije osnovne grupe optimizacijskih problema karakterističnih za građevinske procese:

a) optimizacija resursa

b) optimizacija prostora i ruta.

Tablica 1. Optimizacijski problemi karakteristični za građevinske procese

Domena	Optimizacijski problem	Opis problema	Izvor
Optimizacija resursa	Problemi dodjele zadataka i resursa (eng. *assignment problem*, AP).	AP predstavlja problem kako dodijeliti određeni broj zadataka određenom broju agenata (resursa) gdje svaki agent može izvršiti bilo koji zadatak i pri čemu stvara trošak koji se mijenja ovisno o zadatku, a svi zadaci se moraju izvršiti s time da se može dodijeliti točno jedan agent jednom zadatku i pri čemu je potrebno ukupne troškove minimizirati.	[66]
	Problem planiranja projekta (eng. *project scheduling problems*, PSP).	PSP predstavlja širok skup optimizacijskih problema koji se često svedu na jednu dominantnu funkciju cilja minimiziranja ukupnih troškova projekta. Ako je problem proširen ciljnim funkcijama minimizacije trajanja i troškova projekta, tada je problem poznat kao problem balansiranja trajanja i troškova projekta (eng. *time-cost trade-off problems*, TCTO), a ako uključuju i optimizaciju preostalih resursa, tada su identificirani kao problemi optimizacije trajanja, troškova i ostalih resursa projekta (eng. *time-cost-resource optimization problems*, TCRO).	[67]
	Transportni problem (eng. *transportation problem*, TP).	TP je definiran kao program rješavanja istovremenog transporta nekog dobra iz više izvorišta (ishodišta) na više ponora (odredišta) s funkcijom cilja minimizacije ukupnih troškova transporta. TP općenito predstavlja zatvoreni graf toka materijala gdje su jedinični transportni troškovi, kapacitete izvorišta i potražnje ponora ulazni parametri dok su količine materijala koje se trebaju transportirati iz izvorišta u odredišta nepoznanice.	[68]
Optimizacija prostora i ruta	Problem povezanog usmjeravanja (eng. *arc routing problem*, ARP).	ARP predstavlja povezani graf konstruiran od dvije skupine točaka (izvori i odredišta) za koje je potrebno pronaći zatvorenu rutu koja posjećuje svaku točku odredišta najmanje jedanput ili potvrditi da takva ruta ne postoji.	[69, 70]
	Kapacitirani problem povezanog usmjeravanja (eng. *capacitated arc routing problem*, CARP).	CARP ima zadatak pronaći broj takvih ruta čije su veze s pozitivnom potražnjom opslužene točno jednim vozilom, pri čemu suma potražnje veza ne prelazi ukupni kapacitet i pri čemu su ukupni troškovi ruta minimizirani.	[71]
	Problem kineskog poštara (eng. *Chinese postman problem*, CPP).	CPP je definiran spojenim neusmjerenim grafom s poznatom matricom udaljenosti i koji opisuje problem kako pronaći rutu koja prolazi svakom točkom grafa najmanje jednom najkraćim mogućim putem.	[72]
	Problem trgovačkog putnika (eng. *traveling salesman problem,* TSP)	TSP je definiran kao optimizacijski problem trgovačkog putnika koji treba putovati od početne lokacije do svake određene lokacije, te nakon posjeta svih lokacija jednom, vratiti se na početnu lokaciju pri ciljnoj funkciji minimalne rute putovanja ili minimalnog vremena putovanja.	[73]
	Problem usmjeravanja vozila (eng. *vehicle routing problem*, VRP)	VRP je problem optimalnog usmjeravanja flote jednakih vozila iz centralnog polazišta kako bi opskrbili odredišta poznatih potražnji uzimajući u obzir ograničenje kapaciteta vozila.	[74]

Tablica 2. Primijenjeni optimizacijski problemi orijentirani na resurse u građevinarstvu

Period	Opis primijenjenog problema	Metode, modeli i alati	Glavna dostignuća i zaključci	Izvor
1997. - 2000.	TCTO problem planiranja građevinskog projekta s 18 aktivnosti.	Autori su razvili novi algoritam, koji kombinira uporabu genetičkog algoritma (GA) i Paretovog pristupa.	Predstavljeni algoritam se pokazao učinkovitim i točnim pri rješavanju zadanog problema jer se pretraga svela samo na mali dio prostora mogućih rješenja. Također, autori su razvili računalni program TCGA koji koristi Microsoft Excel i automatizira korištenje njihovog algoritma.	[75]
	TCTO problem generiranih 16 građevinskih projekata s 11 aktivnosti.	Strojno učenje na sistemu genetičkog algoritma (MLGAS).	Prethodne analitičke tehnike su ograničavale uporabu genetičkih algoritama zbog nužnosti manualnog unosa podataka za krivulju odnosa troškova i vremena, i to samo u linearnom obliku. MLGAS nadilazi spomenuta ograničenja primjenom strojnog učenja pomoću genetičkih algoritama.	[76]
	Višekriterijska optimizacija alokacije i balansiranja resursa na studiji slučaja projekta s 20 aktivnosti i 6 resursa.	Primijenjen je genetički algoritam pomoću Microsoft Visual Basic (VBA) programskog jezika.	Glavni doprinos predstavljenog pristupa je napredak u heuristici alokacije resursa koristeći se proizvoljnim prioritetima aktivnosti. Osim toga, primijećena je i praktična modifikacija balansiranja resursa koristeći se dvostrukim pristupom te istovremena optimizacija alokacije i balansiranja resursa.	[77]
	Niveliranje više dostupnih resursa u građevinskom projektu s 9 aktivnosti i strogo zadanim krajem projekta, uz funkciju cilja minimiziranja varijacije iskorištenja resursa.	Model niveliranja resursa baziran na genetičkom algoritmu (GARLS).	GARLS model ne zahtjeva niti jedno heurističko pravilo, čime je fleksibilniji za rješavanje kompleksnijih problema niveliranja i planiranja resursa. GARLS nudi nekoliko izvedivih ili skoro-optimalnih rješenja koja će pomoći u procesu odlučivanja u projektu. U ovom istraživanju autori su uspješno upotrijebili različite računalne pakete za primjenu GARLS modela (MS Project, MS Access, MS Excel, i VBA). Autori preporučuju u daljnjim istraživanjima modifikaciju predstavljenog modela za rješavanje i TCTO problema.	[78]
2001. – 2010.	Problem repetitivnog planiranja projekta proizvodnje predgotovljenih elemenata s višenamjenskim resursima.	Model za rješavanje problema je baziran na genetičkom algoritmu uz korištenje programskog jezika Microsoft Visual Basic-a.	Autori su istaknuli da predstavljeni model koristi efektnu računalnu tehniku za alokaciju resursa i primjereniji način modeliranja dijeljenja resursa u repetitivnom planiranju, u odnosu na linearne tehnika planiranja. Model baziran na genetičkom algoritmu ne zahtijeva posebno heurističko pravilo i time je fleksibilan. Također, ovim pristupom se može istražiti i koristiti više gotovo optimalnih rješenja, koja obično nisu dostupna pri korištenju konvencionalnih metoda repetitivnog planiranja.	[79]
	Problem repetitivnog planiranja projekta koji se sastoji od 4 slična segmenta, gdje svaki segment uključuje ponavljajuće aktivnosti u međusobnim vezama početak-kraj bez vremenskih odgoda.	Automatizirani model dinamičkog programiranja.	Zaključeno je da se modelom, s obzirom na njegovu automatiziranost, definiranje obveznih međusobnih odnosa između aktivnosti znatno olakšava. Također, značajno umanjuje broj isključujućih veza, što poboljšava i ubrzava proces optimizacije te omogućuje generiranje optimalnog rješenja.	[80]
	TCRO problem građevinskog projekta s 12 aktivnosti i pretpostavkom da ne postoje ograničenja prioritetnih odnosa između idućih aktivnosti.	Niveliranje resursa pomoću modela proširene Lagrangeove metode bazirane na GA.	Predloženi model omogućuje prezentaciju linearnog ili nelinearnog odnosa troškova i trajanja te odnosa resursa u vremenu trajanja projekta. Nadalje, model je sposoban rješavati širok spektar projekata s obzirom na njihovu zahtjevnost i brojnost aktivnosti. Model je uspješno implementiran u FORTRAN računalni jezik za potrebe rješavanja problema planiranja resursa na nekoliko primjera građevinskih projekata.	[81]
	Višekriterijski TCTO problem s uzimanjem u obzir različitih pondera između kriterija optimizacije na primjeru projekta sa 7 aktivnosti.	GA orijentirani model s prilagodivim ponderima kriterija.	Autori su istaknuli da ovakav pristup pruža više slobode genetičkom algoritmu pri pretraživanju višekriterijskog područja. No, s obzirom na to da model koristi GA, generiranje slučajnih varijabli može utjecati na rezultat pretrage i pouzdanost rezultata.	[82]
	PSP s ograničenim resursima te funkcijom cilja minimiziranja trajanja projekta. (RCPSP)	Meta-heuristička PSO metoda.	Na temelju računalne analize, autori su zaključili da permutacijski PSO nadmašuje prioritetni PSO te da metodologija bazirana na PSO ima jednako dobre rezultate kao druge metaheurističke metode poput genetičkom algoritmu i SA za rješavanje RCPSP.	[83]
	Stohastički višekriterijski TCRO problem s neizrazitim varijablama vremena i troškova.	Model stohastičkog optimiziranja korištenjem nedominantnih sortirajućih GA-ama (NSGA-II).	Predstavljeni model poboljšava prethodno razvijene pristupe ponderiranja primjenom trodimenzionalnog Paretovog pristupa. Također, model usvaja neizrazite setove čime se uzimaju u obzir neizvjesnosti trajanja i troškova aktivnosti u projektu te se omogućuje razmatranje različitih razina neizvjesnosti pomoću α-prereza razina. Autori predlažu daljnji razvoj modela u smjeru diskretiziranja aktivnosti u projektu.	[84]
	PSP u slučajevima više smjenskog rada u građevinskim projektima uz funkciju cilja minimiziranja trajanja, ukupnih troškova i negativnih utjecaja rada u večernjim i noćnim smjenama.	Optimizacijski model koji uključuje tri modula: • inicijalizaciju optimizacije vremenskog plana • modul izrade vremenskog plana • modul višekriterijskog GA-tma	Model se pokazao sposobnim za ocjenu i identifikaciju sustava optimalnih smjena u projektu već u prvoj iteraciji. Također, model nudi optimalno rješenje uz minimizaciju trajanja projekta, troškova i raspoređivanje radnika u večernje i noćne smjene, gdje svako rješenje identificira optimalni plan i više-smjenski rad za svaku aktivnost. Model generira optimalni plan raspodjelom ograničeno dostupnih radnika na radne smjene s ciljem minimiziranja negativnog utjecaja kasnog rada na učinkovitost radnika.	[85]

Tablica 2. Primijenjeni optimizacijski problemi orijentirani na resurse u građevinarstvu - nastavak

2011. – 2016.	Nelinearni kvadratni AP (QAP) za određivanje lokacije materijala i toranjske dizalice.	MILP model.	Prema numeričkom primjeru, autori su ponudili bolji rezultat koristeći se MILP modelom, u odnosu na rezultat pomoću GA-tma, uz gotovo 7 % uštede ukupnih troškova transporta materijala. Nadalje, MILP formulacija je fleksibilnija u vidu uključivanja dodatnih ograničenja koji modeliraju uvjete na gradilištu.	[86]
	Nelinearni diskretni TCTO problem građevinskog projekta s 29 aktivnosti (NDTCTOP).	MINLP model.	Predloženi model je kompleksniji i zahtijeva više uloženog analitičkog (proračunskog) truda u odnosu na MILP model. No, autori su primijetili prednost modela u pogledu mogućnosti modeliranja problema. Također, model nudi optimalno rješenje NDTCTOP, dok heurističke metode uglavnom to ne mogu.	[87]
	PSP projekta s modularnom oplatom.	Višekriterijski optimizacijski model baziran na diskretnom algoritmu krijesnice (DFA).	Vjerodostojnost optimizacijskog modela je dokazana time što je model ponudio bolje rješenje alokacije radne snage radi balansa troškova i trajanja projekta.	[88]
	TCTO problem građevinskog projekta s manjim brojem značajnih aktivnosti.	PSO metoda optimizacije projekta preko kritičnog puta korištenjem MATLAB računalnog paketa.	Autori su uspješno primijenili PSO metodu za optimizaciju plana izvršenja građevinskog projekta. Predstavljeni model osigurava dobre rezultate i nudi nekoliko prednosti u odnosu na metode bazirane na simpleks algoritme linearnog programiranja te ostale tradicionalne matematičke metode programiranja.	[89]
	NDTCTO problem građevinskog projekta s ne-konveksnom funkcijom troškova.	MINLP model.	MINLP optimizacijski model za rješavanje problema s nekonveksnim odnosima pokazao se kao alat kojim se smanjuje uloženi trud pri rješavanju problema s velikim bazama podataka te pri ažuriranju modela uslijed izmjena uvjeta u kojima je projekt planiran. Uporaba nelinearnih izraza može omogućiti kompaktniju formulaciju modela i ubrzati proces upravljanja aktivnostima, poput transformacije podataka u ulazne parametre i modifikacije modela.	[90]
	AP i optimalna alokacija resursa u višeprojektnom okruženju.	Binarni više-kriterijski i scenarijsko-simulacijski model.	Model se pokazao kao koristan alat za rješavanje malih i srednje velikih problema. Prilagodljiv je promjenama ulaznih parametara. Također, nudi usporedbu optimalnog i suboptimalnih rješenja.	[91]
	PSP uz čvrsto ograničene troškove projekta.	MINLP model.	Predstavljeni MINLP model obuhvatio je ukupne troškove projekta, generalizirane prioritetne odnose, vremenska ograničenja, logičke funkcije te ograničenja troškova aktivnosti.	[92]
	TP vruće asfaltne mješavine	Evolucijski algoritam višekriterijskog pristupa (MCS).	Rezultati su pokazali da je pristup vjerodostojan alat za rješavanje problema planiranja transporta vruće asfaltne mješavine kada ukupno vrijeme realizacije projekta nije ograničeno. Autori ističu da je potrebna modifikacija modela za rješavanje velikih problema te uzimanje u obzir vremenskih i tehnoloških međusobnih utjecaja potprocesa u lancu.	[93]

Ovdje treba naglasiti da postoji puno varijacija optimizacijskih problema koji su definirani drugačijim funkcijama ciljeva i ograničenjima, a koji su vrijedni analize i razrade, no zbog ograničene dužine ovog rada, nisu razmatrani.

4.2. Sažeti pregled nedavnih primjena optimizacije u građevinskim procesima

Zbog složene prirode građevinskih problema i ciklične veze procesa planiranja i optimizacije, teško je identificirati samo jedan tip od navedenih originalnih optimizacijskih problema, pa čak i razlikovati ih u potpunosti. Većina optimizacijskih problema u građevinarstvu su kombinacija raznih originalnih optimizacijskih problema. Stoga je teško i sažeti sve primijenjene metoda za rješavanje takvih problema. No, u ovom poglavlju autori ipak daju sažeti pregled nedavnih i najpoznatijih (u većini slučajeva često citiranih) primjena, metoda i modela optimizacijskih problema u građevinarstvu. Pregled je dan u obliku dviju kronološki poredanih tablica, tako što se u tablici 2. prikazuje pregled optimizacijskih problema orijentiranih na resurse, a u tablici 3. pregled problema koji su orijentirani na prostor i rute.

Optimizacijski problemi prostora i ruta, karakteristični za građevinske procese, kronološki su poredani u tablici 3. počevši od 1995. godine. Budući da primjeri ovih tipova problema nisu brojni kao prethodni oni nisu razdvojeni u posebne vremenske periode.

5. Optimizacija i BIM

5.1. Općenite poveznice između optimizacije i BIM-a

Potencijali i koristi optimizacije u raznim područjima građevinarstva su neosporni. Glavni cilj ovog poglavlja je predstaviti uspostavljene poveznice između optimizacije i koncepta modeliranja informacijskog sustava građevina (eng. *building information modelling* - BIM), a koje su prikazane u relevantnim znanstvenim radovima. Unatoč brzo razvijajućim područjima, pregledom literature utvrđeno je da ne postoji puno radova koji su dali pregled stanja i dosega povezivanja tih dvaju koncepata. Cilj je ovog poglavlja predočiti najnovija dostignuća u povezivanju optimizacije i BIM-a, a u svrhu identificiranja potencijala budućih istraživanja.

Tablica 3. Primijenjeni optimizacijski problemi prostora i ruta u građevinskim procesima

Opis primijenjenog problema	Metode, modeli i alati	Doprinosi i zaključci	Izvor
Planiranje pristupnih ruta za velika vozila na gradilišta industrijskih objekata.	Planiranje ruta je izrađeno uz pomoć stručnog sustava Nexpert Object i geografskog informacijskog sustava (GIS), vezama informacija i poveznica pomoću CAD-a, računalnog paketa Microstation, računalnim programom Excel, te ostalim računalnim programima.	Osim scenarijske "što ako" analize, autori su istaknuli da korisnik predstavljenim sustavom može odabrati parametre za modifikaciju, modificirati ih i potom testirati rezultate modifikacije. Autori predlažu daljnji rad na nesigurnostima modela i identifikaciji područja rizika potencijalnih ruta, kvantifikaciji korisničkih prioriteta koristeći se pristupom neizrazite logike te prezentaciji strategije i znanja potrebnih za scenarijsku modifikaciju.	[94]
Problem uređenja gradilišta (CSLP) uz funkciju cilja minimiziranja ukupnih troškova transporta materijala.	GA generira početnu populaciju rješenja uređenja kroz sekvencu mutacije i otuda se evolucijski razvijaju rješenja populacije uz glavni cilj pronalaska optimalnog uređenja gradilišta.	Autori ističu da je ključni doprinos predstavljenog algoritma to što on koristi veliki broj različitih operatora GA-tma radi variranja pozicija objekata gradilišnog uređenja. Operatori GA-tma su programirani tako da se vjerojatnost izvedivog pozicioniranja odabranog objekta maksimizira, uz funkciju kojom se pronalaze i pohranjuju setovi izvedivih rješenja za svaki pojedini objekt. Također, algoritam pohranjuje u svakoj generaciji kromosoma parcijalno rješenje uređenja. Ti takozvani "loši" kromosomi se čuvaju kako bi se procesu evolucije rješenja pomoglo da izađe iz područja lokalnog optimuma.	[95]
Problem vremenskog planiranja, planiranja resursa i optimizacija troškova velikih programa građenja i održavanja koji uključuju više odredišta s ciljevima pronalaska optimalnog seta metoda i optimalne rute između odredišta.	Autori su predložili distribucijski model vremenskog planiranja (DSM) koji koristi GA-tme za određivanje skupa građevinskih zahvata i optimalnu rutu između gradilišta.	U svrhu određivanja prigodne tehnologije te listu dostupnih i prigodnih građevina za njihovo uključivanje u društvene programe izgradnje i/ili održavanja DSM se pokazao nužnim dodatnim alatom za realizaciju programa. Koristi modela su određivanja broja potrebnih radnih grupa i njihovog operativnog plana, analiza osjetljivosti s obzirom na određivanje početka realizacije programa te određivanje ograničenja dinamičkog okruženja i ažuriranje uslijed promjena tijekom realizacije.	[96]
Dispečerski i problemi logistike koji se pojavljuju tijekom aktivnosti sanacija nakon nepogoda i kriznih situacija, a karakteriziraju ih problemi ruta privremenih prometnica i umjeravanja vozila te problem višestruke robne isporuke.	Metaheuristička metoda optimizacije mravlje kolonije (ACO) koja grupira originalni problem logistike u dvije iteracijske faze.	Uspoređujući rješenje s onim dobivenim računalnim programom CPLEX, kvalitetno rješenje ACO algoritma je dobiveno unutar jedne minute što je naročito važno s obzirom na krizne okolnosti, neizvjesnost i dinamičnost informacija. Potrebno je naglasiti da metaheurističke lokalne pretrage, kao što je tabu-pretraga, zahtijevaju dodatnu analizu za utvrđivanje njihove učinkovitosti. Osim toga, treba spomenuti da lokalno pretraživanje u postoptimalnoj proceduri ne poboljšava rješenje iako se neka provizijska kvaliteta poboljšava u tom procesu. Rezultati pokazuju da ovaj pristup grupiranja može biti koristan i za neke kompleksne kombinatorijske probleme s neovisnim varijablama.	[97]
Prometni zastoji i problem planiranja bazirani na ponašanju u prometu i promjene ruta sudionika u prometu.	Mikrosimulacijski model koji primjenjuje timsku pretragu optimizacijom kolonije mrava (TACO) za pronalazak gotovo optimalnog plana uz korištenje računalnog simulacijskog programa VISSIM.	Rezultati su pokazali da predloženi model može značajno smanjiti ukupno vrijeme zastoja u prometu. U usporedbi s drugim matematičkim metodama, mikrosimulacija zahtijeva više vremena za proračun, no okruženje modela je bliže realnom što ga čini pouzdanijim alatom.	[98]
VRP auto miješalica pri dovozu betonskih mješavina i povratku na postrojenja za proizvodnju betona..	Kombinacija MILP modela s generičkim pristupom lokalnog pretraživanja koristeći se programom CPLEX.	Općeniti MILP solver je neadekvatan za rješavanje velikih realnih problema. Za rješavanje spomenutih problema, autori su kombinirali MILP s pristupom lokalnog pretraživanja. Predstavljeni pristup se zasniva na pretpostavci da su svi podaci dostupni za proračun. Stoga autori predlažu ovaj pristup kao prigodan alat za izradu početnog plana.	[99]
CSLP.	Integrirani simulacijski sustav koji uključuje kompleksno pretraživanje i GA-tme koristeći se platformom Simphony.	Predstavljeni simulacijski sustav se može jednostavno proširiti kako bi se prilagodio više disciplina i strategija u svrhu postizanja naprednijeg rješenja. Razvijeni sustav omogućuje stručnjacima u projektima tuneloizgradnje izradu modela i testiranje različitih scenarija bez dodatnih uputa od strane autora sustava.	[100]
Dinamični, višekriterijski CSLP s nejednakim područjima.	Max–Min mravlji sustav (MMAS) i modificirani Paretov pristup baziran na ACO algoritmu. Za ocjenu i odabir razine korištena je intuitivna neizrazita metoda TOPSIS.	Učinak CSLP sustava donošenja odluka je verificiran na studiji slučaja stambene zgrade. Pokazao se kao koristan alat menadžerima i planerima pri uređenju gradilišta s više međusobno proturječnih ili sukladnih ciljeva. Također, pomaže korisnicima pri uređenju gradilišta uključujući ostale kvalitativne faktore, kao što su olakšavanje, nadzor i kontrolu.	[101]
VRP modeliran kao višestruko tretirani kapacitirani ARP uz vremenska ograničenja (MTCARPTW).	MTCARPTW je transformiran u TSP kako bi se primijenio heuristički ACO algoritam.	Rezultati su pokazali da je ovaj pristup učinkovit za MTCARPTW koji se sastoji manje od 50 čvorova, uz dobro i relativno brzo rješenje. Autori predlažu da se u budućim istraživanjima pokuša proširiti problem na praktičnu razinu složenosti kako bi se ispitalo daje li ACO algoritam bolje rezultate pri rješavanju MTCARPTW u odnosu na ostale heurističke metode te kako će se povećanje broja tipova usluga odraziti na učinkovitost pristupa.	[102]
CSLP lociranja toranjska dizalice uz optimizaciju količina potražnje i ponude materijala.	Autori su usporedili relativne učinke PBA, PSO i BA za rješavanje spomenutog problema.	Rezultati su pokazali da PBA ima najbolja rješenja u odnosu na ostala dva algoritma. Iako je PBA ponudio najbolja rješenja pri optimalnom lociranju dizalice, ovaj algoritam ne može minimizirati operativne troškove opskrbe u slučajevima višedimenzijskih problema	[103]
Logistički i dispečerski problem opskrbe gradilišta betonskom mješavinom.	Autori su usporedili robusni GA i stupčastu generaciju (CG) za rješavanje realnih problema različitih veličina	Rezultati su pokazali da u prosjeku CG osigurava uštedu troškova oko 20 %. Robusni GA konvergira 40 % brže nego CG, dok je broj neangažiranih klijenata u oba pristupa gotovo jednak.	[104]
Problem opskrbe gradilišta betonskom mješavinom.	Autori su predstavili scenarijski simulacijski model koristeći se računalnim programom Enterprise Dynamics.	Predstavljeni model se pokazao kao koristan za rješavanje malih i srednje velikih problema opskrbe gradilišta betonskom mješavinom. Osigurava optimalno rješenje uz generiranje suboptimalnih scenarija, što pomaže pri donošenju odluka uslijed eventualnih promjena u realizaciji programa opskrbe. Ovisnost modela o internetskim kartama je jedno od glavnih ograničenja primjene modela.	[105]

Paradigma BIM-a je jedna od najperspektivnijih u razvoju građevinarstva, arhitekture i općenito inženjerstva [106]. Najčešća definicija upućuje na to da je BIM u suštini suradnja sudionika tijekom svih faza životnog ciklusa građevinskog projekta s naglaskom na izradi, razvrstavanju i razmjeni zajedničkih 3D modela i inteligentnih, strukturiranih podataka koji su im pridruženi [107]. BIM model je podatkovno obogaćena, objektno orijentirana i inteligentna parametarska prezentacija fizičkih i funkcionalnih karakteristika transformiranih u višedimenzijski digitalni (računalni) model. Sve karakteristike građevina BIM-om su dostupne korisniku.

Primjena BIM-a se jasno može kategorizirati s obzirom na osnovni fokus. U većini BIM alata transformacija precizne sintetičke baze podataka u virtualnu realnost se obavlja posredno (ručno) i najčešće sadrži 3D geometrijski model uz ostale vizualizirane informacije, tzv. dimenzije. Ovaj pristup se može nazvati i pasivni BIM zbog nedostatka analitičke podrške modelu.

Za analizu strukturnih podataka, kao što su optimalni vremenski plan i plan uređenja gradilišta, kontrola rizika, kontrola sigurnosti na radu ili izgradivost, treba se koristiti dodatnim alatima uz nužna korisnikova računalna znanja i vještine.

U strogo matematičkom smislu, BIM kao koncept nije optimizacijski pristup sve dok se ne primjeni jedna od optimizacijskih metoda i dok se modelu ne doda output uz dinamičku vezu. Na taj način su razlike između simuliranog i optimalnog rješenja jasne. Kao što je već navedeno, ovo poglavlje je orijentirano na nedavno objavljena dostignuća povezanih koncepata BIM i optimizacije, gdje se BIM može nazvati aktivni BIM. U tim slučajevima modeli funkcioniraju preko algoritama. U sljedećim potpoglavljima dan je pregled primjena i dostignuća aktivnog BIM-a, a koje, osim optimizacijskih tehnika, karakterizira i primjena u građevinarstvu (problemi AP, CSLP i PSP).

5.2. Primjene aktivnog BIM-a

U tablici 4. prikazan je kronološki pregled primjena aktivnog BIM-a, a koje su integriranjem optimizacijskih tehnika i BIM-a rezultirale optimalnim rješenjima koja su pridonijela transparentnosti optimizacijskih modela, ali i pretvorbu pasivnog u aktivni BIM.

Primjene aktivnog BIM-a u rješavanju problema planiranja građevinskih projekata (PSP) prikazane su i kronološki poredane u tablici 5.

Tablica 4. Primjene aktivnog BIM-a za rješavanje problema AP i/ili CSLP

Godina	Opis problema	Metode, modeli i alati	Doprinosi i zaključci	Izvor
2003*.	AP pri pronalasku optimalnih pozicija privremenih objekata u CSLP.	Autori su razvili novi algoritam koristeći GA na CAD platformi.	U radu je zaključeno da sam GA ne osigurava optimalno rješenje CSLP, no može ponuditi gotovo optimalno rješenje. Pri minimizaciji funkcije cilja, GA obavlja kompleksan zadatak pozicioniranja privremenih objekata na konzistentnim udaljenostima s obzirom na potrebe.	[108]
2005*.	AP pri optimizaciji lokacija dizalica i objekata.	Metoda koja koristi GA.	Značajne vremenske uštede se mogu ostvariti korištenjem GA modela za pozicioniranja dizalica na gradilištu. Postavljanje dva tipa kromosoma pokazalo se korisno za generiranje GA modela. Prvi kromosomi su povezani s kodom pozicije krana, a drugi s brojem kranova. U budućim radovima predlaže se proširenje u smislu integriranja i korištenja hibridnog GA modela s 3D vizualizacijom.	[109]
2010*.	CSLP u projektima proširenja zračnih luka.	Autori su razvili model GA-tma višekriterijske optimizacije: maksimizacije sigurnosti na radu, sigurnosti letjelica te ostalih aspekata sigurnosti uz minimizaciju troškova.	Rezultati su generirani i vizualizirani uz pomoć sustava CAD. Autori su zaključili da je pristup koristan inženjerima pri planiranju i optimizaciji uređenja gradilišta u projektima proširenja zračnih luka. No, treba naglasiti da je primijenjeni 2D model ograničen i da se u daljnjim istraživanjima preporučuje prijelaz u 3D.	[110]
2014.	BIM orijentiran CSLP uzimajući u obzir realne rute kretanja.	GA je primjenjen za generiranje dinamičkog CSLP modela. Korišten je računalni program Autodesk Revit kao BIM alat, a Microsoft Project za vremensko planiranje. Osim spomenutih, razvijen je i vlastiti računalni program kojim se očitavaju računske tablice iz računalnog programa Microsoft Excela.	Rezultati su pokazali da optimizacijski modeli, orijentirani na linearne udaljenosti i minimizaciju kretanja radne snage na gradilištu, mogu ponuditi suboptimalna rješenja uređenja gradilišta, stoga su korištene stvarne udaljenosti. Primjenom metode generiralo se uređenje gradilišta uz uštedu od 16,5 % ukupne potrebne udaljenosti za prijelaz radne snage. Buduće istraživanje ovog modela može ići u smjeru integracije u 4D model te simulaciju.	[111]
2015.	BIM orijentiran i automatiziran CSLP u slučajevima zagušenih gradilišta.	GA je primijenjen za generiranje dinamičkog CSLP modela. Proračuni su izrađeni pomoću podataka iz BIM modela.	Rezultati su dokazali uštedu u zbroju ukupnih udaljenosti na gradilištu od 13,5 %, u odnosu na konvencionalne metode. Autori su zaključili da konvencionalni algoritam koji koristi neposredne udaljenosti nije adekvatan alat. Model ima potencijal proširenja realnim vremenskim planovima projekata i modela logistike dostave materijala.	[112]
2015.	BIM orijentiran CSLP za optimizaciju troškova gradilišta.	GA, BIM i identifikator radijske frekvencije (RFID) kombinirani su radi optimizacije generacija rješenja uređenja gradilišta u realnom vremenu.	S obzirom na rezultate, zaključeno je da je predstavljeni sustav sposoban automatski pratiti privremene objekte i modelirati slobodne prostore na gradilištu u odnosu na funkciju cilja minimiziranja troškova.	[113]

Tablica 4. Primjene aktivnog BIM-a za rješavanje problema AP i/ili CSLP - nastavak

2014. 2015.	AP za generiranje plana operiranja toranjske dizalice.	BIM je primijenjen za automatsko generiranje potrebnih količina materijala za transport na gradilištu. FA orijentirana optimizacijska metoda je primijenjena za određivanje pozicije toranjske dizalice, izvorišnih i odredišnih točki transporta materijala.	Rezultati su pokazali da se primjenom metode ostvaruje ušteda vremena za izradu plana operiranja krana u odnosu na tradicionalnu metodu, posebice u slučaju više angažiranih kranova. Metoda je također pokazala uštede ukupnih troškova transporta materijala i kolizija, a s obzirom na vizualizaciju rješenja, radnici na gradilištu mogu jednostavno shvatiti i precizno implementirati shemu uređenja gradilišta.	[114] [115]
2015.	AP za optimalno pozicioniranje i odabir tipa toranjske dizalice.	Metoda analitičkog hijerarhijskog procesa (AHP) je primijenjena za višekriterijsko odlučivanje odabira toranjske dizalice. GA je korišten za optimalno pozicioniranje i plan operiranja krana. BIM model je korišten za izvoz količina potrebnih za GA.	Rezultati su pokazali da je primjena AHP metode za odabir tipa krana značajna i osjetljivija u smislu najviše kritičnih kriterija za odabir. Predstavljeni primjer je pokazao da je toranjska dizalica s „krunom" tornja najosjetljiviji tip kranova s obzirom na najviše koeficijente osjetljivosti. Autori su zaključili da se BIM model toranjske dizalice može izraditi dodajući više funkcionalnosti, poput omogućavanja napredne funkcije prostornih ograničenja ili modeliranja mobilnih dizalica.	[116]
2016.	AP za određivanje frekvencija kretanja u CSLP, uz funkciju cilja minimiziranja troškova kretanja.	Predstavljena je integracija ulaznih podataka iz BIM modela i procjene rasporeda i frekvencije kretanja. Analiza je programirana u VBA-u radi povezivanja informacija prikupljenih iz BIM modela i plana projekta. Procijenjene frekvencije kretanja su poslužile kao ulazni podaci CSLP modeliranog kao problem MILP.	Rezultati su pokazali mogućnosti predstavljenog modela u automatizaciji procesa procjene frekvencije kretanja na gradilištu. Autori su zaključili da vrijednosti frekvencija kretanja korištenih iz drugih projekata mogu generirati pogreške u procesu optimizacije. U daljnjem razvoju istraživanja preporučuje se razvoj i poboljšanje preciznosti modela u vidu prikupljanja i stvaranja svoje baze podataka iz više tipova projekata.	[117]
2016.	AP za pozicioniranje dizalice i odredišnih točaka za dostavu materijala uzimajući u obzir operativne i režijske troškove.	MILP model za optimalno pozicioniranje krana uz minimizaciju ukupnih troškova. Problem iz studije slučaja je linearizirani i riješen koristeći solver CPLEX računalnog programa.	Pozicija krana dobivena predloženim modelom upozorila je na značajne razlike kada kapacitet krana nije uzet u obzir. U tom slučaju zabilježena je ušteda oko 30 % ukupnih troškova, a primjenom MILP modela. No, rezultati su pokazali da zanemarivanje kapaciteta krana može dovesti do pogreške čak i do 20 % u odnosu na optimalni rezultat.	[118]

** Radovi čiji doprinos uključuje primjenu CAD sustava, no koji se smatraju prethodnicom primjene aktivnog BIM-a. Važnost je tih radova u povezivanju optimizacijskih metoda i CAD alata za rješavanje problema u građevinskim procesima.*

Tablica 5. Primjena aktivnog BIM-a za rješavanje problema PSP

Godina	Opis problema	Metode, modeli i alati	Doprinosi i zaključci	Izvor
2008*.	PSP za integrirani plan vrijeme/troškovi.	Korištena je matrica dijela objekata (OSM) i GA te više-dimenzijski CAD model.	U radu je u šest glavnih koraka predstavljena metodologija primjene GA-tma za optimizaciju dijela građenja i određivanja zadataka grupama radnika. Model uzima u obzir ograničenja resursa, radnog prostora i produktivnosti.	[119]
2012.	PSP i problem konflikta radnih prostora.	Primijenjen je GA za minimizaciju konflikata radnih prostora uz korištenje 4D CAD sustava.	Prezentirano istraživanje je pokazalo da je prije optimizacije konflikata radnih prostora potrebno odrediti model radnih prostora i proračunski omjer konflikata. Nadalje, susjedni radni prostori se mogu analizirati te se mogu odrediti konflikti u planovima radova. Podaci se mogu optimizirati pomoću GA-tma te dobiti rezultati s najmanjim trajanjima međusobnih konflikata prostora i radova. Očekivano je da se sve funkcije koriste kao osnovni podaci za stvaranje okruženja aktivnog BIM-a. U ovome radu se najvjerojatnije prvi puta spominje termin "aktivni BIM"	[120]
2013.	PSP za smanjivanje preklapanja planova.	Primijenjen je BIM uz neizrazitu teorijsku funkciju kvantifikacije rizika građenja. GA je korišten za optimizaciju planova.	Smanjivanje razine preklapanja planova građevinskog projekta, sa svakom generacijom GA-tma, može se vizualno provjeriti u okruženju aktivnog BIM-a. Dobiveni rezultati pokazuju da predloženi model GA-tma može pridonijeti smanjenju preklapanja planova za otprilike 33 %.	[121]
2013.	PSP s minimalnom razinom preklapanja.	Primijenjeni su GA i neizrazita analiza rizika.	Autori su pokazali da se u svakoj generaciji rezultati mogu vizualno kontrolirati u aktivnom BIM-u. Pokazano je da se GA-tmom, osim optimizacije planova, mogu planirati radovi od početka.	[122]
2014.	PSP za smanjivanje preklapanje planova.	Primijenjeni su revidirani GA za minimiziranje plana i konflikata radnih prostora te simulacijski model BIM-a za vizualizaciju rješenja.	Autori su zaključili da se njihov sustav može karakterizirati kao alat aktivnog BIM-a i koji se može primijeniti uz minimalna specijalizirana znanja administratora. Rezultati istraživanja pokazuju na vrijednost utjecaja konflikata planova i prostora koja je smanjena na 26,4 % od planirane vrijednosti (što je 73,6 % u odnosu na plan). No, promatrani slučaj je jednostavan tip problema te je nužna njegova detaljna modifikacija za primjenu na drugim projektima.	[123]

Tablica 5. Primjena aktivnog BIM-a za rješavanje problema PSP - nastavak

2014.	PSP za generiranje novog plana.	Za generiranje novog plana primjenjen je GA i matrica ograničenja izgradivosti (MoCC).	Rezultati su pokazali da primijenjeni pristup može rezultirati potpuno izvedivim planom. Fitnes funkcija GA-tma može ispitati izgradivost odgovarajućih aktivnosti, a konflikte radova/prostora menadžeri mogu vizualno kontrolirati. Autori zaključuju da se model može nadograditi modificiranjem 3D čitača, korelacijskim koeficijentima, izmjenom formulacije gena GA-tma, i slično.	[124]
2015.	PSP za generiranje novog plana.	Primijenjeni su GA i MoCC za generiranje plana, a Autodesk Revit za BIM.	Rezultati su pokazali da predloženi pristup može biti učinkovit za generiranje plana u dva stupnja između jednostavnog i složenog. Eksperiment je proveden na veoma jednostavnom primjeru BIM modela pri čemu je rješenje grubo konvergiralo globalnom optimumu.	[125]
2015.	PSP uz ograničenja resursa.	Primijenjeni su evolucijski PSO algoritam, programska aplikacija u Revit-u (API) u C# programskom jeziku; baza informacija o aktivnostima za BIM model iz programa Microsoft Access te Microsoft Project uz očitavanje XML dokumenata i simulacijski program Symphony.	Rezultati upućuju na to da je sustav sposoban ponuditi plan u slučaju prekoračenja roka i ugovorne kazne. Dobiveno rješenje možda i nije globalni optimum, jer rezultati uključuju i neradne dane. Sustav je ograničen jer se trajanja i učinkovitost temelje na menadžerskom iskustvu, ograničenja vremenskih uvjeta nisu uzeta u obzir, simulacija se pokreće neposredno od strane korisnika, itd. Spomenuta ograničenja predstavljaju izazove budućim istraživanjima.	[126]
2015.	TCTO problem uključujući i kvalitetu..	Za optimizaciju planova korišten je GA. Objekti BIM modela su transferirani iz BIM okruženja u bazu podataka tabličnog zapisa uz pomoć grafičkih konvertera. Za očitanje količina strukturiran je programski kod, a u Microsoft Projectu izrađivao se plan.	Istraživanje je pokazalo da predloženi model može demonstrirati uspostavljenu balansiranu vezu kvalitete i troškovno optimiziranog plana generiranog pomoću GA-tma. Autori su zaključili da praktična primjenjivost modela treba biti testirana zbog različitosti utjecajnih faktora realnih uvjeta.	[127]
2016.	PSP građevinskog projekta u odnosu na optimizaciju vremena, troškova i kretanja na gradilištu.	Višekriterijski GA, MoCC i 2D Paretov pristup za generiranje novog plana.	Rezultati su pokazali razliku između troškovno i vremenski orijentiranog pristupa proračunu u modelu GA-tma. Troškovi su porasli u vremenski orijentiranom proračunu i smanjili se u troškovno orijentiranom, kao što je bilo i očekivano. Ograničenje primjene ovog pristupa je veliki broj iteracija proračuna GA-tma. Autori su zaključili da buduća istraživanja trebaju verificirati bolju prezentaciju veza između ciljeva optimizacije uz pomoć neke druge metode višekriterijske optimizacije. Također, više tipova 3D elemenata je potrebno kako bi se generirali realniji rezultati.	[128]
2017.	PSP za optimizaciju planova.	Primijenjena je metoda simuliranja kritičnog puta za generiranje početnog plana, dok je za optimizaciju plana primijenjena tabu-metoda pretraživanja.	Autori su zaključili da upotreba tabu algoritma pretraživanja može biti korisno sredstvo za određivanje optimalnog plana. Ponderi funkcija ciljeva su postavljeni kao ograničenja. Rješavanje problema iz studije slučaja je rezultiralo smanjenjem ukupnog trajanja projekta za 13 %, smanjenjem troškova za 4 % i 49-postotnom porastu fluktuacije resursa. Autori su zaključili da se ovom metodom uspješno može poboljšati plan uz više kriterija optimizacije.	[129]

6. Rasprava i zaključci

Glavna motivacija ovog rada je predstaviti stanje područja optimizacijskih metoda, alata za modeliranje te njihovu primjenu u optimizaciji građevinskih procesa. Autori su stoga najprije dali kratak uvod u problematiku, a zatim dva poglavlja u kojima su prikazane metode i alati za modeliranje koji se danas uspješno koriste za optimizaciju. Danas je korisniku dostupna široka ponuda moćnih optimizacijskih algoritama, bilo heurističkih ili egzaktnih, te brojne mogućnosti modeliranja optimizacijskih problema, kao što su algebarski jezici za modeliranje, proračunske tablice, specijalizirani samostalni optimizacijski računalni programi, interaktivni računalni (programski) jezici ili internetske aplikacije za optimizaciju.

Potom su autori dali kratak pregled optimizacijskih problema koji se prepoznaju u građevinskim procesima, uključujući njihove originalne izvore i definicije, kao i uspješne aplikacije, primijenjene metode rješavanja te ishode. Nakon pregleda originalnih problema i primjena, autori primjećuju da su u većini slučajeva moderne aplikacije optimizacije u građevinskim procesima ekstenzije odnosno modifikacije originalnih formulacija optimizacijskih problema i da se za rješavanje tih problema koriste modeli s raznim kombinacijama egzaktnih, heurističkih, metaheurističkih ili hiperheurističkih metoda. No, jasno je vidljiv trend novijih istraživanja gdje se istraživači fokusiraju na razvijanje heurističkih metoda (naročito GA, PSO, ACO, itd.) za rješavanje optimizacijskih problema u građevinskim procesima.

Da bi istaknuli potencijal područja, autori su prikazali i različite primjene optimizacije u BIM konceptu. U pregledu je prikazano da se za rješavanje BIM orijentiranih problema dodjeljivanja zadataka, organizacija gradilišta i planiranje projekata (što su i najčešće aplikacije problema u ovom pristupu) uglavnom primjenjuju heurističke metode GA-tma. U području egzaktnog matematičkog programiranja identificirani su samo poneki pokušaji optimizacije pomoću kombinacije MILP-a i BIM-a, te postoji velika praznina u tom području za daljnja istraživanja. Sličan zaključak se može donijeti za područje kombiniranja bioinspiriranih optimizacijskih metoda te BIM-a, kao i za matematičku optimizaciju ERP sustava. Na taj način je popunjena praznina u literaturi.

Iz perspektive upravljanja građevinskim poslovanjem može se zaključiti da se informacijski sustavi mogu uspješno primijeniti za procese poput pripreme, planiranja, nadzora, kontrole i drugih. Štoviše, ti se sustavi mogu adekvatno koristiti i nakon gradnje, primjerice za upravljanje održavanjem, rekonstrukcijom i postupcima rušenja. Međutim, veza između informacijskih sustava (poput ERP-a i BIM-a) i optimizacije trenutačno izgleda kao izazovna zadaća kojom se treba intenzivnije baviti.

Ubrzani razvoj modela za donošenje odluka, koji kombiniraju različite optimizacijske pristupe i informacijske sustave, daje jasnu viziju ovog područja u budućnosti. Osim toga, očekuje se da će povezivanje tih dviju rastućih disciplina potaknuti novi val razvoja aktivnog BIM-a za automatiziranje procesa u području upravljanja građevinskim projektima. Međutim, još uvijek postoji niz NP-kompletnih i NP ških problema koji se sadašnjim softverom i hardverom ne mogu egzaktno optimalno riješiti u razumnom računalnom vremenu. Stoga je potrebno naglasiti da će razvoj ovog područja i u budućnosti znatno ovisiti o raspoloživim kapacitetima računala.

Zahvala

Autori zahvaljuju za financijsku podršku Slovenske agencije za znanost (Istraživački fond broj P2-0129) i internom financijskom podupiranju istraživanja mladih istraživača od strane Tehničkog sveučilišta u Brnu, broj FAST-J-14-2363.

LITERATURA

[1] Vukomanović, M., Radujković, M., Dolaček Alduk, Z.: The use of project management software in construction industry of Southeast Europe, Tehnički vjesnik, 19 (2012) 2, pp. 249-258.

[2] Radujković, M., Vukomanović, M., Dunović, I.B.: Application of key performance indicators in South Eastern European construction, Journal of Civil Engineering and Management, 16 (2010) 4, pp. 521-530.

[3] Yubin, Z., Honghai, M., Wangwei, Z., Jiayu, Z.: Simulation and Optimization of the Flow in ERP System for MMI, Proceedings of the 2009 2nd International Congress on Image and Signal Processing, CISP'09, art. no. 5303966, 2009.

[4] Zheng, J., Liu, H., Zeng, S.: The application of particle swarm optimization algorithm in the production scheduling modeling of ERP-based, Applied Mechanics and Materials, 130-134 (2012), pp. 4092-4097, https://doi.org/10.4028/www.scientific.net/AMM.130-134.4092

[5] Ghosh, S., Negahban, S., Kwak, Y.H., Skibniewski, M.J.: Impact of sustainability on integration and interoperability between BIM and ERP - A governance framework, Proceedings of the 1st International Technology Management Conference, ITMC 2011, art. no. 5995975, pp. 187-193, 2011.

[6] Hadidi, L., Assaf, S., Alkhiami, A.: A systematic approach for ERP implementation in the construction industry, Journal of Civil Engineering and Management, 23 (2017) 5, pp. 594-603.

[7] Kolarić, S., Vukomanović, M.: Application of ERP Systems within Construction Industry and Probable Directions of Further Research, 13th International Conference on Organization, Technology and Management in Construction - OTMC 2017, pp. 54-67, Poreč, Croatia.

[8] Hardin, B. & McCool, D.: BIM and construction management: proven tools, methods, and workflows, 2nd edition, John Wiley & Sons, 2015.

[9] Hooke, R., Jeeves, T.A.: Direct Search Solution of Numerical and Statistical Problems, Journal of the Association of Computing Machinery, 8 (1961) 2, pp. 212-229.

[10] Rechenberg, I.: Cybernetic solution path of an experimental Problem, (Royal aircraft establishment translation no. 1122, BF toms, trans.), Farnsborough Hants: Ministery of Aviation, Royal Aircraft Establishment, 1122, pp. 1965.

[11] Schwefel, H.P.: Kybernetische Evolution als Strategie der experimentellen Forschung in der Strömungstechnik, Master's thesis, Technical University of Berlin, pp. 1965.

[12] Holland, J.H.: Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence, U Michigan Press, 1975.

[13] Golberg, D.E.: Genetic algorithms in search, optimization, and machine learning, Addion wesley, pp. 102, 1989.

[14] Glover, F.: Heuristics for integer programming using surrogate constraints, Decision Sciences, 8 (1977) 1, pp. 156-166.

[15] Kirkpatrick, S., Gelatt, C.D., Vecchi, M.P.: Optimization by simulated annealing, science, 220 (1983) 4598, pp. 671-680.

[16] Rumelhart, D., Hinton, G., R. Williams, R.: Learning representations by back-propagating errors, Nature 323, pp. 533-538, 1986.

[17] Colorni, A., Dorigo, M., Maniezzo, V.: Distributed optimization by ant colonies. Proceedings of the first European conference on artificial life: Paris, France; pp. 134-142.1991.

[18] Kennedy, J., Eberhart, R.: Particle Swarm Optimization. Perth, Australia: IEEE Service Center, 1995, https://doi.org/10.1109/ICNN.1995.488968

[19] Storn, R., Price, K.: Differential evolution–a simple and efficient heuristic for global optimization over continuous spaces, Journal of global optimization, 11 (1997) 4, pp. 341-359.

[20] Geem, Z.W., Kim, J.H., Loganathan, G.: A new heuristic optimization algorithm: harmony search, Simulation, 76 (2001) 2, pp. 60-68.

[21] Passino, K.M.: Biomimicry of bacterial foraging for distributed optimization and control, IEEE control systems, 22 (2002) 3, pp. 52-67.

[22] Yang, X.S., Deb, S.: Cuckoo search via Lévy flights. Nature & Biologically Inspired Computing, 2009 NaBIC 2009 World Congress on: IEEE; pp. 210-214.2009.

[23] Karaboga, D., Basturk, B.: A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm, Journal of global optimization, 39 (2007) 3, pp. 459-471.

[24] Yang, X.S.: Firefly algorithms for multimodal optimization. International Symposium on Stochastic Algorithms: Springer; pp. 169-178, 2009, https://doi.org/10.1007/978-3-642-04944-6_14

[25] Yang, X.S.: A new metaheuristic bat-inspired algorithm Nature inspired cooperative strategies for optimization (NICSO 2010), Springer, pp. 65-74, 2010, https://doi.org/10.1007/978-3-642-12538-6_6

[26] Yang, X.S., Karamanoglu, M., He, X.: Flower pollination algorithm: a novel approach for multiobjective optimization, Engineering Optimization, 46 (2014) 9, pp. 1222-1237.

[27] Cui, Z., Cai, X.: Artificial Plant Optimization Algorithm, Swarm Intelligence and Bio-Inspired Computation: Theory and Applications, pp. 351, 2013.

[28] Fong, S., Deb, S., Yang, X.S.: A heuristic optimization method inspired by wolf preying behavior, Neural Computing and Applications, 26 (2015) 7, pp. 1725-1738.

[29] Dantzig, G.B.: Linear programming and extensions, Princeton university press, 1963.

[30] Karmarkar, N. A new polynomial-time algorithm for linear programming. Proceedings of the sixteenth annual ACM symposium on Theory of computing: ACM; pp. 302-311,1984, https://doi.org/10.1145/800057.808695

[31] Abadie, J., Carpentier, J.: Generalization of the Wolfe reduced gradient method to the case of nonlinear constraints, Optimization, 37 (1969), pp. 47.

[32] Powell, M.J.: A method for non-linear constraints in minimization problems, UKAEA, 1967.

[33] Hestenes, M.R.: Multiplier and gradient methods, Journal of optimization theory and applications, 4 (1969) 5, pp. 303-320.

[34] Powell, M.J.: A fast algorithm for nonlinearly constrained optimization calculations. Numerical analysis: Springer; pp. 144-157.1978.

[35] Land, A.H., Doig, A.G.: An automatic method for solving discrete programming problems, Econometrica, 28 (1960) 3, pp. 497-520.

[36] Gomory, R.E.: Outline of an algorithm for integer solutions to linear programs, Bulletin of the American Mathematical Society, 64 (1958) 5, pp. 275–278.

[37] Padberg, M., Rinaldi, G.: Optimization of a 532-city symmetric traveling salesman problem by branch and cut, Operations Research Letters, 6 (1987) 1, pp. 1-7.

[38] Geoffrion, A.M.: Generalized benders decomposition, Journal of optimization theory and applications, 10 (1972) 4, pp. 237-260.

[39] Beale, E.M.L.: Integer Programming The State of the Art in Numerical Analysis, Jacobs D, Academic Press, London, pp. 409–448, 1977.

[40] Mawengkang, H., Murtagh, B.: Solving nonlinear integer programs with large-scale optimization software, Annals of Operations Research, 5 (1986) 2, pp. 425-437.

[41] Olsen, G.R., Vanderplaats, G.N.: Method for nonlinear optimization with discrete design variables, AIAA journal, 27 (1989) 11, pp. 1584-1589.

[42] Westerlund, T., Pettersson, F.: An extended cutting plane method for solving convex MINLP problems, Computers & Chemical Engineering, 19 (1995), pp. 131-136, https://doi.org/10.1016/0098-1354(95)87027-X

[43] Viswanathan, J., Grossmann, I.E.: A combined penalty function and outer-approximation method for MINLP optimization, Computers & Chemical Engineering, 14 (1990) 7, pp. 769-782.

[44] Ryoo, H.S., Sahinidis, N.V.: A branch-and-reduce approach to global optimization, Journal of global optimization, 8 (1996) 2, pp. 107-138.

[45] Adjiman, C.S., Androulakis, I.P., Floudas, C.A.: Global optimization of mixedinteger nonlinear problems, AIChE Journal, 46 (2000) 9, pp. 1769-1797.

[46] Bonami, P., Biegler, L.T., Conn, A.R., Cornuéjols, G., Grossmann, I.E., Laird, C.D. et al.: An algorithmic framework for convex mixed integer nonlinear programs, Discrete Optimization, 5 (2008) 2, pp. 186-204.

[47] Bisschop, J., Roelofs, M.: AIMMS language reference, Lulu. com, 2006.

[48] Fourer, R., Gay, D.M., Kernighan, B.W.: A modeling language for mathematical programming, Management Science, 36 (1990) 5, pp. 519-554.

[49] Lucas, C., Mitra, G.: Computer-assisted mathematical programming (modelling) system: CAMPS, The Computer Journal, 31 (1988) 4, pp. 364-375.

[50] Brooke, A., Kendrick, D., Meeraus, A., Raman, R. GAMS: A User's Guide, GAMS Development Corporation. Washington, DC: GAMS Development Corporation.2015.

[51] Lingo User's Guide. Chicago, IL: LINDO Systems Inc.2015.

[52] Hürlimann, T., Cardona, L.: Modeling tools for decision support: LPL: a modeling language: gLPS: a Graph-Based System for Linear Problems Modeling: NetCalc: a netform editor: CHRIS: a constraint programming tool, Computer Institute of the University of Fribourg, 1993.

[53] MPL Modelling System, Release 5.0. Maximal Software Inc.2015.

[54] Heisig, G., Minner, S.: ILOG OPL Studio, OR Spectrum, 21 (1999) 4, pp. 419-427.

[55] Ellison, E.F., Mitra, G.: UIMP: User interface for mathematical programming, ACM Transactions on Mathematical Software (TOMS), 8 (1982) 3, pp. 229-255.

[56] Evolver: Sophisticated Optimization for Spreadsheets, Version 7. Palisade Corporation ltd.2015.

[57] Frontline Solvers Version 2015-R2, User's Guide. Frontline Systems Inc.2015.

[58] What'sBest Version 13.0 User's Manual. Lindo Systems Inc.2015.

[59] Yih-Long, C. WinQSB: Decision Support Software for MS/OM, Version 2.0. John Wiley & Sons.2003.

[60] Gurobi Optimizer 5.0. Gurobi Optimization Inc. .2012.

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

[62] Battiti, R., Brunato, M.: The LION Way: Machine Learning plus Intelligent Optimization, 2014.

[63] Wolfram, S.: The Mathematica® book, Cambridge University Press, 2003.

[64] Optimization Toolbox 7.3 User's Guide. The MathWorks Inc.2015.

[65] Czyzyk, J., Mesnier, M.P., Moré, J.J.: The NEOS server, Computing in Science & Engineering, 3 (1998), pp. 68-75, https://doi.org/10.1109/99.714603

[66] Kuhn, H.W.: The Hungarian method for the assignment problem, Naval research logistics quarterly, 2 (1955) 1-2, pp. 83-97, https://doi.org/10.1002/nav.3800020102

[67] Icmeli, O., Selcuk Erenguc, S., Zappe, C. J.: Project scheduling problems: a survey, International Journal of Operations & Production Management, 13 (1993) 11, pp. 80-91.

[68] Hitchcock, F.L.: The distribution of a product from several sources to numerous localities, J Math phys, 20 (1941) 2, pp. 224-230.

[69] Sachs, H., Stiebitz, M., Wilson, R.J.: An historical note: Euler's Königsberg letters, Journal of Graph Theory, 12 (1988) 1, pp. 133-139.

[70] Golden, B.L., Raghavan, S., Wasil, E.A.: The vehicle routing problem: latest advances and new challenges, Springer Science & Business Media, 2008, https://doi.org/10.1007/978-0-387-77778-8

[71] Golden, B.L., Wong, R.T.: Capacitated arc routing problems, Networks, 11 (1981) 3, pp. 305-315.

[72] Kwan, M.K.: Graphic programming using odd or even points, Chinese Math, 1 (1962) 110, pp. 273-277.

[73] Flood, M.M.: The traveling-salesman problem, Operations Research, 4 (1956) 1, pp. 61-75.

[74] Dantzig, G.B., Ramser, J.H.: The truck dispatching problem, Management Science, 6 (1959) 1, pp. 80-91.

[75] Feng, C.W., Liu, L., Burns, S.A.: Using genetic algorithms to solve construction time-cost trade-off problems, Journal of Computing in Civil Engineering, 11 (1997) 3, pp. 184-189.

[76] Li, H., Cao, J.N., Love, P.: Using machine learning and GA to solve time-cost trade-off problems, Journal of Construction Engineering and Management, 125 (1999) 5, pp. 347-353.

[77] Hegazy, T.: Optimization of resource allocation and leveling using genetic algorithms, Journal of Construction Engineering and Management, 125 (1999) 3, pp. 167-175.

[78] Leu, S.S., Yang, C.H., Huang, J.C.: Resource leveling in construction by genetic algorithm-based optimization and its decision support system application, Automation in Construction, 10 (2000) 1, pp. 27-41.

[79] Leu, S.S., Hwang, S.T.: Optimal repetitive scheduling model with shareable resource constraint, Journal of Construction Engineering and Management, 127 (2001) 4, pp. 270-280.

[80] El-Rayes, K., Moselhi, O.: Optimizing resource utilization for repetitive construction projects, Journal of Construction Engineering and Management, 127 (2001) 1, pp. 18-27.

[81] Senouci, A.B., Eldin, N.N.: Use of genetic algorithms in resource scheduling of construction projects, Journal of Construction Engineering and Management, 130 (2004) 6, pp. 869-877.

[82] Zheng, D.X., Ng, S.T., Kumaraswamy, M.M.: Applying a genetic algorithm-based multiobjective approach for time-cost optimization, Journal of Construction Engineering and Management, 130 (2004) 2, pp. 168-176.

[83] Zhang, H., Li, X., Li, H., Huang, F.: Particle swarm optimization-based schemes for resource-constrained project scheduling, Automation in Construction, 14 (2005) 3, pp. 393-404.

[84] Zahraie, B., Tavakolan, M.: Stochastic time-cost-resource utilization optimization using nondominated sorting genetic algorithm and discrete fuzzy sets, Journal of Construction Engineering and Management, 135 (2009) 11, pp. 1162-1171.

[85] Jun, D.H., El-Rayes, K.: Optimizing the utilization of multiple labor shifts in construction projects, Automation in Construction, 19 (2010) 2, pp. 109-119.

[86] Huang, C., Wong, C.K., Tam, C.M.: Optimization of tower crane and material supply locations in a high-rise building site by mixed-integer linear programming, Automation in Construction, 20 (2011) 5, pp. 571-580.

[87] Klanšek, U., Pšunder, M.: MINLP optimization model for the nonlinear discrete time–cost trade-off problem, Advances in Engineering Software, 48 (2012), pp. 6-16, https://doi.org/10.1016/j.advengsoft.2012.01.006

[88] Liu, J., Hou, L., Wang, X.: A discrete firefly algorithm for the scaffolding modular construction in mega projects. The 31st International Symposium on Automation and Robotics in Construction and Mining (ISARC 2014), 2014, https://doi.org/10.22260/ISARC2014/0039

[89] Praščević, N., Praščević, Ž.: Application of particle swarms for project time-cost optimization, Građevinar, 66 (2015) 12, pp. 1097-1107.

[90] Cajzek, R., Klanšek, U.: Mixed-integer nonlinear programming based optimal time scheduling of construction projects under nonconvex costs, Tehnicki vjesnik/Technical Gazette, 23 (2016) 1, pp. 9-18.

[91] Galić, M., Završki, I., Dolaček-Alduk, Z.: Scenario simulation model for optimized allocation of construction machinery, Građevinar, 68 (2016) 2, pp. 105-112.

[92] Klanšek, U.: Mixed-Integer Nonlinear Programming Model for Nonlinear Discrete Optimization of Project Schedules under Restricted Costs, Journal of Construction Engineering and Management, 142 (2016) 3, pp. 1-13.

[93] Galić, M., Završki, I., Dolaček-Alduk, Z.: Methodology and algorithm for asphalt supply chain optimization, Tehnički vjesnik - Techical Gazette, 23 (2016) 4, pp. 2016.

[94] Varghese, K., O'Connor, J.: Routing large vehicles on industrial construction sites, Journal of Construction Engineering and Management, 121 (1995) 1, pp. 1-12.

[95] Zouein, P., Harmanani, H., Hajar, A.: Genetic algorithm for solving site layout problem with unequal-size and constrained facilities, Journal of Computing in Civil Engineering, 16 (2002) 2, pp. 143-151.

[96] Hegazy, T., Elhakeem, A., Elbeltagi, E.: Distributed scheduling model for infrastructure networks, Journal of Construction Engineering and Management, 130 (2004) 2, pp. 160-167.

[97] Yi, W., Kumar, A.: Ant colony optimization for disaster relief operations, Transportation Research Part E: Logistics and Transportation Review, 43 (2007) 6, pp. 660-672.

[98] Lee, H.Y.: Optimizing schedule for improving the traffic impact of work zone on roads, Automation in Construction, 18 (2009) 8, pp. 1034-1044.

[99] Asbach, L., Dorndorf, U., Pesch, E.: Analysis, modeling and solution of the concrete delivery problem, European Journal of Operational Research, 193 (2009) 3, pp. 820-835.

[100] Zhou, F., AbouRizk, S.M., Al-Battaineh, H.: Optimisation of construction site layout using a hybrid simulation-based system, Simulation Modelling Practice and Theory, 17 (2009) 2, pp. 348-363.

[101] Ning, X., Lam, K.C., Lam, M.C.K.: A decision-making system for construction site layout planning, Automation in Construction, 20 (2011) 4, pp. 459-473.

[102] Huang, S.H., Lin, P.C.: Multi-treatment capacitated arc routing of construction machinery in Taiwan's smooth road project, Automation in Construction, 21 (2012) ,pp. 210-218.

[103] Lien, L.C., Cheng, M.Y.: Particle bee algorithm for tower crane layout with material quantity supply and demand optimization, Automation in Construction, 45 (2014), pp. 25-32.

[104] Maghrebi, M., Periaraj, V., Waller, S.T., Sammut, C.: Solving ready-mixed concrete delivery problems: evolutionary comparison between column generation and robust genetic algorithm, Computing in Civil and Building Engineering, pp. 1417-1424, 2014.

[105] Galić, M., Kraus, I.: Simulation Model for Scenario Optimization of the Ready-Mix Concrete Delivery Problem, Selected Scientific Papers: Journal of Civil Engineering, 11 (2016) 2, pp. 7-18.

[106] Eastman, C.M., Teicholz, P., Sacks, R., Liston, K.: BIM handbook: A guide to building information modeling for owners, managers, designers, engineers and contractors, John Wiley & Sons, 2011.

[107] The Building Information Modelling (BIM) Task Group http://www.bimtaskgroup.org/bim-faqs/, 24.06.2016.

[108] Osman, H.M., Georgy, M.E., Ibrahim, M. E.: A hybrid CAD-based construction site layout planning system using genetic algorithms, Automation in Construction, 12 (2003) 6, pp. 749-764.

[109] Alkriz, K., Mangin, J.C: A new model for optimizing the location of cranes and construction facilities using genetic algorithms. Khosrowshahi, F (Ed.), 21st Annual ARCOM Conference, 7-9 September 2005, SOAS, University of London. Association of Researchers in Construction Management, 2 (2005), pp. 981-991.

[110] Khalafallah, A., El-Rayes, K.: Automated multi-objective optimization system for airport site layouts, Automation in Construction, 20 (2011) 4, pp. 313-320.

[111] Cheng, J.C.P., Kumar, S.S.: A BIM based construction site layout planning framework considering actual travel paths. Proc, 31st Int Symp on Automation and Robotics in Construction and Mining, International Association for Automation and Robotics in Construction (IAARC), Bratislava, Slovakia, pp. 450-457, 2014.

[112] Kumar, S.S., Cheng J.C.P.: A BIM-based automated site layout planning framework for congested construction sites. Automation in Construction, 59 (2015), pp. 24-37.

[113] Akanmu, A., Olatuni O., Love E.D.P., Nguyen, S., Matthews, J.: Auto-generated site layout: An integrated approach to real-time sensing of temporary facilities in infrastructure projects. Structure and Infrastructure Engineering, 12 (2015), pp. 1243-1255.

[114] Wang, W.C., Weng, S.W., Wang, S.H., Chen, C.Y.: Integrating building information models with construction process simulations for project scheduling support, Automation in Construction, 37 (2014), pp. 68-80.

[115] Wang, J., Zhang, X., Shou, W., Wang, X., Xu, B., Kim, M. J. et al.: A BIM-based approach for automated tower crane layout planning, Automation in Construction, 59 (2015), pp. 168-178.

[116] Marzouk, M., Abubakr, A.: Decision support for tower crane selection with building information models and genetic algorithms. Automation in Construction, 61 (2016), pp. 1-15.

[117] Hammad, A.W.A., Akbarnezhad, A., Rey, D., Waller, S.T.: A Computational Method for Estimating Travel Frequencies in Site Layout Planning, Journal of Construction Engineering and Management, 142 (2015) 5, pp. 04015102.

[118] Nadoushani, Z.S.M., Ammad, A.W.A.H., Akbarnezhad, A.: Location Optimization of Tower Crane and Allocation of Material Supply Points in a Construction Site Considering Operating and Rental Costs, Journal of Construction Engineering and Management, 143 (2017) 1, p. 1-13.

[119] Feng, C.W., Chen, Y.J., Huang, J.R.: Using the MD CAD model to develop the time–cost integrated schedule for construction projects, Automation in Construction, 19 (2010) 3, pp. 347-356.

[120] Moon, H., Kim, H., Kang, L., Kim, C.: BIM functions for optimized construction management in civil engineering. 29th International Symposium of Automation and Robotics in Construction, pp. 67, 2012.

[121] Kim, H.S., Moon, S.Y., Moon, H.S., Kang, L.S.: Application of information technology for visualizing and optimizing construction project schedule, 15th International Conference on Enterprise Information Systems, pp. 329-332, 2013

[122] Moon, H., Kim, H., Kamat, V.R., Kang, L.: BIM-based construction scheduling method using optimization theory for reducing activity overlaps, Journal of Computing in Civil Engineering, 29 (2013) 3, pp. 04014048.

[123] Moon, H., Kim, H., Kim, C., Kang, L.: Development of a schedule-workspace interference management system simultaneously considering the overlap level of parallel schedules and workspaces, Automation in Construction, 39 (2014), pp. 93-105.

[124] Faghihi, V., Reinschmidt, K.F., Kang, J.H.: Construction scheduling using genetic algorithm based on building information model, Expert Systems with Applications, 41 (2014) 16, pp. 7565-7578.

[125] Wang, H., Song, X.S.: Research on BIM construction schedule generating algorithm, International Journal of Simulation: Systems, Science and Technology, 16 (2015) 1B, pp. 10.11-10.17.

[126] Liu, H., Al-Hussein, M., Lu, M.: BIM-based integrated approach for detailed construction scheduling under resource constraints, Automation in Construction, 53 (2015), pp. 29-43.

[127] Xu, Y., Wei, Y.: Study on trade-off of time-cost-quality in construction project based on BIM, 2015 International Conference on Economics, Social Science, Arts, Education and Management Engineering, 2015.

[128] Faghihi, V., Reinschmidt, K.F., Kang, J.H.: Objective-driven and Pareto front analysis: Optimizing time, cost, and job-site movements, Automation in Construction, 69 (2016), pp. 79-88.

[129] De Soto, B.G., Rosarius, A., Rieger, J., Chen, Q., Adey, B.T.: Using a Tabu-search Algorithm and 4D Models to Improve Construction Project Schedules, Procedia Engineering, 196 (2017), pp. 698-705.