# Računalna potpora metodama optimiranja

**Primorac, Jure**

**Undergraduate thesis / Završni rad**

**2020**

*Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj:* **Josip Juraj Strossmayer University of Osijek, Faculty of Economics in Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Ekonomski fakultet u Osijeku**

*Permanent link / Trajna poveznica:* https://urn.nsk.hr/urn:nbn:hr:145:492647

*Rights / Prava:* In copyright / Zaštićeno autorskim pravom.

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

*Repository / Repozitorij:*

EFOS REPOSITORY - Repository of the Faculty of Economics in Osijek

Sveučilište Josipa Jurja Strossmayera u Osijeku

Ekonomski fakultet u Osijeku

Preddiplomski studij smjer Financijski menadžment

Jure Primorac

# RAČUNALNA POTPORA METODAMA OPTIMIRANJA

Završni rad

Osijek, 2020

Sveučilište Josipa Jurja Strossmayera u Osijeku

Ekonomski fakultet u Osijeku

Preddiplomski studij smjer Financijski menadžment

Jure Primorac

# RAČUNALNA POTPORA METODAMA OPTIMIRANJA

Završni rad

Kolegij: Kvantitativne metode za poslovno odlučivanje

JMBAG: 0111121871

e-mail: jurevkprimorac@gmail.com

Mentor: izv.prof.dr.sc. Martina Briš Alić

Osijek, 2020

Josip Juraj Strossmayer University of Osijek

Faculty of Economics

Undergraduate Study Financial management

Jure Primorac

# COMPUTER SUPPORT OF OPTIMIZATION METHODS

Final paper

Osijek, 2020

**IZJAVA**

**O AKADEMSKOJ ČESTITOSTI, PRAVU PRIJENOSA INTELEKTUALNOG VLASNIŠTVA, SUGLASNOSTI ZA OBJAVU U INSTITUCIJSKIM REPOZITORIJIMA I ISTOVJETNOSTI DIGITALNE I TISKANE VERZIJE RADA**

1. Kojom izjavljujem i svojim potpisom potvrđujem da je završni rad isključivo rezultat osobnoga rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu. Potvrđujem poštivanje nepovredivosti autorstva te točno citiranje radova drugih autora i referiranje na njih.
2. Kojom izjavljujem da je Ekonomski fakultet u Osijeku, bez naknade u vremenski i teritorijalno neograničenom opsegu, nositelj svih prava intelektualnoga vlasništva u odnosu na navedeni rad pod licencom *Creative Commons Imenovanje – Nekomercijalno – Dijeli pod istim uvjetima 3.0 Hrvatska*.
3. Kojom izjavljujem da sam suglasan/suglasna da se trajno pohrani i objavi moj rad u institucijskom digitalnom repozitoriju Ekonomskoga fakulteta u Osijeku, repozitoriju Sveučilišta Josipa Jurja Strossmayera u Osijeku te javno dostupnom repozitoriju Nacionalne i sveučilišne knjižnice u Zagrebu (u skladu s odredbama Zakona o znanstvenoj djelatnosti i visokom obrazovanju, NN br. 123/03, 198/03, 105/04, 174/04, 02/07, 46/07, 45/09, 63/11, 94/13, 139/13, 101/14, 60/15).
4. izjavljujem da sam autor/autorica predanog rada i da je sadržaj predane elektroničke datoteke u potpunosti istovjetan sa dovršenom tiskanom verzijom rada predanom u svrhu obrane istog.

**Ime i prezime studenta/studentice:**Jure Primorac

**JMBAG:** 0111121871

**OIB:** 33749389780

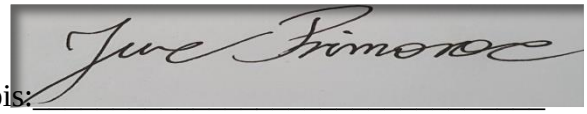
**e-mail za kontakt:** jurevkprimorac@gmail.com

**Naziv studija:**Preddiplomski sveučilišni studij, Smijer Financijski-menadžment

**Naslov rada:**Računalna potpora metodama optimiziranja

**Mentor/mentor za rad:** izv.prof.dr.sc. Martina Briš Alić

U Osijeku, 24. Rujna 2020 godine

Potpis: 

# SAŽETAK

Mnoge poslovne odluke, bilo da se radi o strateškim, operativnim, lokalnim, uključuju identificiranje resursa potrebnih za najbolje rješavanje poslovnih potreba. Takve odluke često uključuju vrlo velik broj kvantitativnih početnih izbora. Na primjer, da bi se stvorio glavni plan proizvodnje, potrebno je odlučiti što će se proizvoditi, gdje, kada, u kojoj količini, kako će se proizvod distribuirati, u kojoj količini i na koju lokaciju. Svi ti izbori moraju biti međusobno dosljedni i moraju udovoljavati specifičnim ograničenjima uz zadani problem. Kako bi se donijele odluke, potrebno je puno procjena i istraživanja koje je teško pripremiti i procijeniti pomoću tradicionalnih metoda. Da bi se napravio najbolji mogući izbor, mora se napraviti optimizirana raspodjela resursa prema nekoliko varijabli, kriterija, koje podliježu skupu ograničenja. Za pronalazak rješenja, koristiti će se jedna od mnogih metoda koje su dio operacijskog istraživanja. Metoda za postizanje rješenja ima nekolicina, a odgovarajuća metoda će biti ona za čije rješavanje postoje poznanice unutar problema. Unutar ovog istraživačkog rada biti će postavljene metode optimiziranja koje služe za dolazak do optimalnih rješenja, na lakši, efikasniji način, međutim, uz određena tehnološka znanja i posjedovanje tehnoloških programa. Za postavljanje istraživanja, koristiti će se jedna od najčešće korištenih metoda optimiziranja, linearna metoda.

Ključne riječi: metode, optimiziranje, operacijsko istraživanje, resursi

# ABSTRACT

Many business decisions, whetherstrategic, operational, local, involve identifying the resources needed to address business needs in best way,Such decisions often involve a very large number of quantitative initial choices. For example, in order to create a master plan of production, it is necessary to decide what will be produced, where, when, in what quantity, how the product will be distributed, in what quantity and at what location. All these choices must be consistent with each other and must meet specific constraints with a given problem. In order to make decisions, a lot of assessments and research are needed that are difficult to prepare and assess using traditional methods. In order to make the best possible choice, an optimized allocation of resources must be made according to several variables, criteria, which are subject to a set of constraints. To find a solution, one of the many methods that are part of operational research will be used. There are several methods for reaching a solution, and the appropriate method will be one for which there are acquaintances within the problem. Within this research work, optimization methods will be set up that serve to arrive at optimal solutions, in an easier, more efficient way, however, with certain technological knowledge and possession of technological programs. To set up the research, one of the most commonly used optimization methods, the linear method, will be used.



Keywords: methods, optimization, operationalresearch, resources

# Sadržaj

UVOD ..... 1

1. METODOLOGIJA RADA ..... 2

2. POVIJESNI RAZVOJ METODA I TEHNOLOGIJA OPERACIJSKOG ISTRAŽIVANJA ..... 3

3.1. Razlozi za optimiziranje ..... 3

3.2. Kriteriji optimiranja ..... 5

3.3. Razvoj operacijskog istraživanja ..... 5

3.4. Povijesni razvoj operacijskih istraživanja i metoda unutar područja ..... 6

3.5. Povezanost razvoja tehnologije s razvojem metoda optimiziranja ..... 8

3. SISTEMATIZACIJA METODA ..... 9

5. PROGRAMSKI (SOFTWARE) PAKETI ZA OPTIMIZIRANJE ..... 11

6. LINEARNO PROGRAMIRANJE ..... 13

6.1. Oblik linearnog programiranja ..... 14

6.2. Primjer transportnog linearnog programiranja ..... 15

6.2.1. Postavljanje problema ..... 15

6.2.2. Funkcija cilja ..... 16

7. DEFINIRANJE PROBLEMA I RIJEŠENJE ..... 17

7.1. Harris Corporation ..... 18

7.2. Zara ..... 18

8. ZAKLJUČAK ..... 20

LITERATURA ..... 21

POPIS SLIKA ..... 22

POPIS TABLICA ..... 22

# UVOD

Donošenje odluka sastavni je dio modernog upravljanja. Racionalno svakodnevno donošenje odluka, primarna je funkcija upravljanja. Odluke igraju važnu ulogu jer određuju i organizacijske i upravljačke aktivnosti. Operativne odluke su u središtu poslovanja svih djelatnosti, od određivanja odgovarajućeg iznosa ulaganja do izračunavanja popusta za vrijednost kupaca. Svaka odluka nosi rizik i tvrtke mogu platiti visoku cijenu za loše donošenje odluka, kako novčanu tako i u kreiranju ugleda. Proces donošenja odluka kontinuirana je i neophodna komponenta upravljanja bilo kojom organizacijom ili poslovnim aktivnostima. Kako se povećao opseg poslovanja jedne tvrtke, tako se povećala i odgovornost upravljanja. Svaki menadžer podsvjesno ili svjesno donosi stotine odluka, a kako bi bio u toku i pratio sve funkcije, te održavao poslovanje na optimalnoj razini, potrebne su mu metode praćenja. Razvojem tehnologije, i način praćenja informacija prešao je s tradicionalnog na potpomognuto računalima. Ovisno o kojem cilju se radi, razvijene su i razne metode za praćenje.

Dizajniranje i upravljanje složenim sustavim, učinkovito rješavanje problema raspodjele oskudnih resursa i razvoj održive strategije za savladavanje sukoba i partnerstva uvijek su bile potrebno i izazovno područje za pojedince, organizacije i gospodarstva. Optimizacija i operacionalizacija su discipline koje se na znanstveni način bave takvim problemima, odnosno, primjenjuju znanstvene metode i informacijsku tehnologiju za rješavanje problema. Optimizacija je ona disciplina unutar primijenjen matematike koja se bavi modelima optimizacije.

# 1. METODOLOGIJA RADA

Uobičajena zabluda mnogih je da su operacijska istraživanja zbirka matematičkih alata. Iako je istina da se koristi raznim matematičkim tehnikama, operacijsko istraživanje ima širi opseg. Zapravo se radi o sustavnom pristupu rješavanju problema koji koristi jedan ili više analitičkih alata u procesu analize. Operacijska istraživanja potpomognuta računalima razvila su brojne metode optimiranja poslovanja.

Cilj završnog rada je prikazati metode koje su se razvile kroz povijest poslovanja, a služe za optimiranje proizvodnje, resursa kao što su ljudi, vrijeme, inputi i sl. Postoji veliki broj modela koji se koriste u tu svrhu, a unutar rada objasniti će se najpopularniji, te će se u sklopu metode linearnog programiranja, metode koja se najviše koristi, prikazati problem i riješiti se.

Predmet završnog rada su metode optimiranja koje se koriste računalnim programima, osim toga, istraživački rad pokušati će riješiti problem u poslovanju pomoću jedne od metoda optimiranja.

Za potrebe pisanja rada korištene su brojne metode kao što su metoda analize i sinteze, induktivna i deduktivna, povijesna metoda, statističke metode.

Rad je sastavljen od osam poglavlja unutar kojima je cilj što detaljnije prikazati na koji način se koristi računalna oprema za potporu metodama optimiranja kao dijelom operacijskih istraživanja. U drugom poglavlju će se prvo objasniti kakva je poveznica između metoda optimiranja i operacijskih istraživanja, kao i kako se kroz povijest razvijalo operacijsko istraživanje. Isto poglavlje prikazati će snagu računalne tehnologije koja je omogućila da operacijska istraživanja budu jednostavnija za korištenje. Sljedeće poglavlje prikazuje koje sve metode za optimiranje postoje i na koji način se mogu koristiti. Peto poglavlje predstavlja softvere koji se koriste za računalno optimiranje. Poglavlje pod nazivom Linearno programiranje objasniti će u koju svrhu se koristi linearno programiranje, ali će i postaviti jedan programski problem koji će se riješiti uz korištenje Excela kao programskog softvera. Predzadnje poglavlje navesti će neke primjere iz ekonomije gdje su se operacijska istraživanja i metode optimiranja pokazale kao jako korisne u poslovanju. Posljednje poglavlje dati će sistematizirani zaključak stvoren na temelju istraživanja.

# 2. POVIJESNI RAZVOJ METODA I TEHNOLOGIJA OPERACIJSKOG ISTRAŽIVANJA

Područje operativnih istraživanja pruža snažniji pristup donošenju odluka od uobičajenih softvera i alata za analitiku podataka. Zapošljavanje stručnjaka iz ovog područja, može pomoći tvrtkama postići cjelovitiji skup podataka, kako bi razmotrili sve mogućnosti, predvidjeli se moguće ishode i procijenili rizik uz svaki scenarij. Osim toga, operativna istraživanja se mogu prilagođavati određenim poslovnim procesima, ili koristiti studijama slučajeva, sve u cilju utvrđivanja tehnike koja je najprikladnija za rješavanje problema.

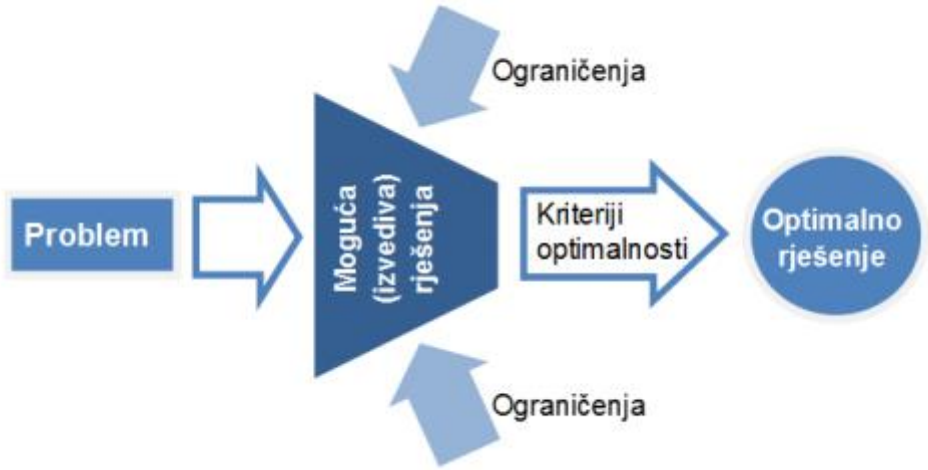
Donošenje najbolje moguće odluke presudno je za uspjeh bilo kojeg poslovanja i zaista može pružiti konkurentnu prednost. To je osobito važno ako se podaci mogu koristiti za donošenje objektivnijih, znanstvenih i, u konačnici, boljih odluka. Vrste odluka koje se mogu donijeti proučavanjem optimiranja mogu se staviti u široki spektar, od strateških uvida na visokoj razini, do svakodnevnih manjih odluka.

Ovisno o složenosti optimiziranja, koristiti će se i prikladan softver za rješavanje takvih modela.

## 3.1. Razlozi za optimiziranje

Za početak istraživanja je potrebno razumjeti sam pojam optimiziranja kako bi se shvatio predmet i cilj završnog rada. ″Optimiziranje (prema lat. optimus: najbolji), matematički postupak kojim se pri projektiranju ili vođenju promatranoga sustava ostvaruje (određuje) najbolji mogući izbor ekonomskih i (ili) tehničkih veličina na temelju odabranih kriterija.″[1] Optimizacija je važan alat u donošenju odluka. Matematički gledano, problem optimizacije je problem pronalaženja najboljeg rješenja između skupa svih izvedivih rješenja. Slika 1. prikazuje od kojih se točno elemenata sastoje metode optimiranja. Optimiranje je pronalazak optimalnog rješenja za problem, ali uz nekoliko ograničenja.

[1] Optimiranje. Hrvatska enciklopedija. Dostupno na. https://www.enciklopedija.hr/natuknica.aspx?ID=45345, (10.09.2020.)




Slika 1.: Postupak optimiranja

Izvor: Stanković, Pašagić – Škrinjar, 2015:9

Za izgradnju optimizacije potrebno je pratiti određene postavljene korake u procesu kako bi model bio odgovarajući, a to su:[2]

- modeliranje,
- odabir kategorije u koju je model optimizacije pripada,
- odabir softvera.

Modeliranje je postupak identificiranja i matematičkog izražavanja cilja, varijabli i ograničenja problema. Cilj je kvantitativna mjera performansi sustava koju se želi minimizirati ili povećati. U proizvodnji, cilj je povećati dobit ili umanjiti troškove proizvodnje, dok u prilagođavanju eksperimentalnih podataka modelu, mogu se umanjiti ukupna odstupanja promatranih podataka od predviđenih podataka. Varijable ili nepoznanice su komponente sustava za koje se želi pronaći vrijednost. U proizvodnji, varijable mogu biti količina svakog utrošenog resursa ili vrijeme provedeno na svakoj aktivnosti. Ograničenja su funkcije koje opisuju odnose među varijablama i koje definiraju dopuštene vrijednosti za varijable. U proizvodnji, količina utrošenih resursa ne može i ne smije premašiti dostupnu količinu. Drugi korak u procesu optimizacije je određivanje u koju kategoriju optimizacije spada model. Treći korak u procesu optimizacije je odabir softvera koji odgovara vrsti problema s optimizacijom. [3]

[2]Introduction to Optimization. Dostupno na. https://neos-guide.org/content/optimization-introduction, (10.09.2020.)
[3]Introduction to Optimization. Dostupno na. https://neos-guide.org/content/optimization-introduction, (10.09.2020.)

### 3.2. Kriteriji optimiranja

″Kriteriji optimiranja proizvodnih procesa mogu biti: maksimalna produktivnost, minimalna cijena proizvoda, maksimalni dohodak i minimalni utrošak energije″ (Crnošija, 2003:179).

Produktivnost je omjer između outputa i inputa. To je kvantitativni odnos između onoga što se proizvodi i količine potrošenoga u proizvodnji. Produktivnost nije ništa drugo nego smanjenje rasipanja resursa (ljudi, materijal, stroj, vrijeme, prostor, kapital i sl.). Poboljšanje produktivnosti znači raditi stvari bolje i činiti ih unutar kontinuiranog procesa. Kada se usvoje tehnike učinkovite produktivnosti, osigurava se rast pojedinca i organizacije. Stalni je napor primijeniti nove tehnike i metode kako bi se napravio napredak. Poboljšanje produktivnosti znači povećanje produktivnosti uz upotrebu iste količine materijala, strojnog vremena, zemlje, rada ili tehnologije. Sljedeći kriterij optimiranja je minimalna cijena proizvoda. To je najniža cijena po kojoj se proizvod može prodavati, nakon što se primijene svi popusti. Ako se kojim slučajem proizvod proda ispod ove cijene, poduzeće će biti na gubitku jer neće uspjeti pokriti troškove proizvodnje. Uz određivanje minimalne cijene proizvoda, potrebno je odrediti i idealne uvijete u kojima je moguće ostvariti maksimalni dohodak, a ta se u isto vrijeme troši najmanje energije, odnosno ne stvara dodatni trošak.

### 3.3. Razvoj operacijskog istraživanja

″Mnogi se stručnjaci slažu da je teško definirati jer ne postoji jedinstveni objekt spoznaje ( kao što je poduzeće u znanosti o ekonomici poduzeća ). Ne bi se, dakle, na gledati kao na zasebnu znanost. S druge strane koriste se sa znanstvenim metodama za rješavanje relevantnih problema, dakle, se mogu shvatiti kao znanstvena disciplina″ (Barković, 1994:133). Operacijsko istraživanje označava istraživanje operacija. Međutim, uzima se u obzir određeni pogled na operacije i određena vrsta istraživanja. Operacijsko istraživanje organizirana je primjena suvremenih znanosti, matematike i računalnih tehnika na složene vojne, državne, poslovne ili industrijske probleme koji nastaju u usmjeravanju i upravljanju velikim sustavima ljudi, materijala, novca i strojeva. Barković (1997:9) navodi kako da su ″operacijska istraživanja kompleksno interdisciplinarno stručno područje. Sva specijalna područja operacijskih istraživanja bave se rješavanjem problema odlučivanja koji imaju podlogu u stvarnosti. U zavisnosti od vrste problema primjenjuju se adekvatni modeli i metode koje

služe za bolje pribavljanje informacija, strukturiranje problema, egzaktno ili približno računanje, koji treba da posluže boljoj transparentnosti stvarnosti.″

Barković (1997:3) daje definiciju operacijskog istraživanja kao ″primjenu kvantitativnih metoda za rješavanje znanstvenih, privrednih problema.″Kako je globalno tržište postajalo sve konkurentnije, operacijska istraživanja su postala sve važnija u poslovanju kod donošenja strateških odluka. Rast globalnih tržišta i rezultirajući porast konkurencije osvijetlili su potrebu za operativnim istraživanjima. Danas je to jedan od popularnih znanstvenih alata za odlučivanje, koje koriste profitne i neprofitne organizacije.

Operacijsko istraživanje je usmjereno na problem, odnosno to je pristup rješavanja problema. Za razliku od matematičkog programiranja, problemi s kojima se operacijsko istraživanje nosi nisu apstraktni i formalni već specifični i stvarni. Druga karakteristika operacijskog istraživanja je da pokušava pronaći najbolje moguće rješenje problema uz pomoć modela za prepoznavanje pravca i djelovanja koji stvara optimalnu izvedbu stvarnog sustava. Drugim riječima, operacijsko istraživanje želi preporučiti optimalnu odluku.

### 3.4. Povijesni razvoj operacijskih istraživanja i metoda unutar područja

″Cournot je 1858. godine izračunao cijenu monopolskog ponuđača kojom postiže maksimalnu dobit, prvi model repova čekanja izradio je za kopenhašku telefonsku mrežu Erlang. Prvi model optimalne količine naručivanja datiraju iz 1915. godine. U dvadesetim godinama ovog stoljeća razvio je Leontijev model input-output analize, a krajem tridesetih godina postavio je J. von Neumann temelje teorije igara, dok je Markov početkom stoljeća obrazložio početke dinamičkog optimiranja. Trideset godina kasnije pojavljuju se prvi radovi Kantoroviča, kojeg bi se moglo smatrati ocem linearnog optimiranja. Usprkos svih ovdje navedenih i nenavedenih radova vrijeme utemeljenja operacijskih istraživanja vezano je za Drugi svjetski rat 1940. – 1945″ (Barković, 2004:4).

Iako ne postoji jasan datum koji obilježava rođenje operativnih istraživanja, ona su kao novo područje započela  u britanskoj vojsci u drugoj polovici 1930-ih kao odgovor na mobilizaciju njemačkog zrakoplovstva. Iako se korijeni vide u ovom periodu povijesti, polazište je temeljeno na Arhimedovim studijama. Arhimed je prikupio empirijske podatke, analizirao ih pomoću matematike i koristio rezultate za izradu opreme i formuliranje metoda. Nakon

Drugog svjetskog rata, operativna istraživanja razvijaju se kao akademska disciplina u akademskom poslovnom okruženju. Mnogo novih tehnika operacijskog istraživanja razvijaju ugledni znanstvenici i primjenjuju ih na mnogo različitih područja. ″Sam pojam 'Operation research' uveden je u istraživačkom odjelu ministarstva zrakoplovstva Velike Britanije u vremenu 1937.-1939. godine pri istraživanju primjene radara u zračnoj obrani, od strane britanskog zračnog ministarstva koji je sačinjavao timove koji su radili ″operativna istraživanja″ komunikacijskog sustava na britanskoj radarskoj stanici. Slijedećih godina razvijene su matematičke analize vojnih problema odlučivanja kako bi se ograničenu količinu vojnog materijala i ljudi potrebnih za određene vojne operacije moglo raspoređivati na što efikasniji način. Smatra se da je uloženi napor znatno smanjio broj žrtava na strani saveznika i da je znatno doprinio njihovoj pobjedi. Nakon rata metodologija operacijskog istraživanja počela se uspješno primjenjivati u mnogim drugim složenim situacijama, od ekonomskih problema do inženjerskih i drugdje.″[4] Danas su operacijska istraživanja dobro razvijeno područne sa sofisticiranim nizom tehnika koje se rutinski koriste za rješavanje problema u širokom rasponu područja primjene.

Nekoliko godina nakon što je nastao u Engleskoj, operacijska istraživanja šire se na SAD, za istraživanje minskog rata američke mornarice, to se na kraju proširilo u to se na kraju proširilo u Anti submarine Warfare Operations Research Group koju je vodio Phillip Morse, koja je kasnije postala poznata jednostavno kao Operations Research Group. Drugi glavni poticaj za rast operacijskih istraživanja bio je razvoj digitalnih računala tijekom sljedeća tri desetljeća. Simplex metoda prvi je put primijenjena na računalu 1950. godine, a do 1960. takve su implementacije mogle riješiti problem s oko 1000 ograničenja. Danas implementacije na moćnim radnim stanicama mogu rutinski rješavati probleme sa stotinama tisuća varijabli i ograničenja. Štoviše, velike količine podataka potrebe za takve probleme mogu se vrlo učinkovito pohraniti i njima manipulirati (Rajgopal, 1997:28).

″Tematske jedinice koje redovito sadrže operacijska istraživanja su (Zelenika, 2015:46):

1) linearno programiranje,
2) višekriterijsko programiranje,
3) cjelobrojno programiranje,
4) mrežno programiranje,

[4]Operacijska istraživanja. Dostupno na. https://www.veleri.hr/files/datotekep/nastavni_materijali/k_promet_2/Operacijska_istrazivanja_1._dio.pdf, (11.09.2020.)

5) teorije igara,
6) redovi čekanja,
7) problemi transporta i distribucije i
8) problemi zaliha.″

### 3.5. Povezanost razvoja tehnologije s razvojem metoda optimiziranja

Razvoj tehnologije je neizmjerno utjecao i na razvoj operacijskih istraživanja. Metode koje su dodatno razvijene i usavršene upotrebom tehnologije, omogućile su rješavanje problema s ogromnom količinom podataka. Kada se danas razmatra pozicija industrije i ekonomije neke zemlje, vidljiva je velika poveznica s razvijenosti računalne tehnologije, i sukladno tome operacijskih istraživanja.

Računalna revolucija, posebno razvoj osobnih računala od 1980-ih, jedan je od glavnih doprinosa razvoju operativnih istraživanja. Danas u računalnoj eri mnoge metode operacijskog istraživanja uključuju složene proračune i stoga im treba i više vremena za pružanje rješenja na stvarne probleme. Razvoj brzih digitalnih računala omogućio je uspješnu primjenu nekih operativnih istraživačkih tehnika za rješavanje kompliciranih problema. Razvoj novijih interaktivnih računala učinio je posao rješavanje velikih problema još jednostavnijim zbog ljudske intervencije prema analizi osjetljivosti (Mengistu, 2013:8).

Jednom kada je simplex metoda izumljena i korištena, brzim tempom razvijale su se i druge metode. Sljedećih dvadesetak godina razvio se veliki broj tehnika metoda optimiziranja koje se i danas koriste, uključujući linearno, cjelobrojno i dinamičko programiranje, računalnu simulaciju, teoriju repova čekanja, model inventara, teoriju igara i mnoge druge. Znanstvenici koji su razvili ove metode potjecali su iz mnogih različitih područja, ponajviše iz matematike, inženjerstva i ekonomije. Zanimljivo je da su teorijske osnove za mnoge od ovih tehnika poznate već godinama, npr. EOQ model (Rajgopal, 1997:28).

Rastom računalne snage ovi su modeli postali izuzetno popularni u posljednja dva desetljeća. Simulacijski model je onaj gdje se sustav implementira u računalni program.

## 3. SISTEMATIZACIJA METODA

″Operacijska istraživanja, kao složeni, dinamički i stohastički sustav mnogobrojnih i različitih znanstvenih subdisciplina i odgovarajućih kvantitativnih, kvalitativnih i međusobno povezanih znanstvenih metoda, omogućavaju iznalaženje optimalnih rješenja, optimalnih projekata, optimalnih modela, optimalnih odluka u svim primarnim, sekundarnim, tercijarnim, kvartarnim djelatnostima. Optimalna rješenja, projekti, modeli, odluke, procesi formuliraju se i predstavljaju u kvantitativnim, kvantitativno-kvalitativnim i kvalitativnim oblicima, a mogu se teorijski i praktično ispitati″ (Zelenika, 2015:46). ″Temeljna je misija svih metoda operacijskih istraživanja: pronalaženje optimalnih (najpovoljnijih) rješenja, modela, procesa, odluka, projekata o određenim problemima i fenomenima u društvu i prirodi. Takva se rješenja, modeli, procesi formuliraju i predstavljaju u kvantitativnim, kvantitativno-kvalitativnim i kvalitativnim oblicima. Optimalna rješenja mogu se odrediti kao minimum i/ili maksimum, što ovisi o karakteristikama primarnih objekata svakog pothvata temeljnih, primijenjenih i razvojnih istraživanja″ (Zelenika, 2015:47-48).

Metode optimiranja mogu se podijeliti prema nekoliko kriterija. Prema tome se pravi podjela metoda optimiranja prema složenosti računanja:

- Metode optimiranja s računanjem samo funkcije cilja (jednostavno traženje rješenja);
    - metode sa skalarnim argumentom (optimiranje jednog parametra, metoda dijeljenja intervala),
    - metode s vektorskim argumentom (simplex metoda po Nelderu i Meadu),
- Optimiranje uz računanje funkcije cilja i njene derivacije;
    - gradijentne metode,
- Metode s računanjem funkcije cilja i njene prve i druge derivacije;
    - Newtonove metode,
    - Kvazi Newtonove metode. (Ban, 11.09.2020.)

Podjela metoda optimiranja s obzirom na ograničenja:

- Metoda optimiranja s ograničenjem;
    - linearno programiranje,
    - nelinearno programiranje (kvadratično programiranje).
    - metoda dijeljenja intervala (optimiranje jednog parametra),
- metode optimiranja bez ograničenja;

- simplex metode,
- gradijentne metode (Newtonovi algoritmi i kvazi Newtonovi algoritmi). (Ban, 11.09.2020.)

Postoji mnogo matematičkih metoda koje se rješavaju s potporom računala, a u daljnjem tekstu biti će prema Zelenika (2015:47-49) navedene najpoznatije:

1) Metode operacijskih istraživanja prema načelima linearnog programiranja.
2) Metode operacijskih istraživanja prema načelima višekriterijskog programiranja.
3) Metode operacijskih istraživanja prema načelima cjelobrojnog programiranja.
4) Metode operacijskih istraživanja prema načelima mrežnog programiranja.
5) Metode operacijskih istraživanja prema načelima teorije igara.
6) Metode operacijskih istraživanja prema načelima teorije repova čekanja.

Rastom računalne snage, ovi su modeli postali izuzetno popularni u posljednjih dvadesetak godina. Putem računala, na temelju određenih modela može se napraviti i simulacijski model gdje se sustav apstrahira u računalni program. Najpopularniji sustavi su OR/MS Today. Tipično takav softver ima sintaksu kao i ugrađene konstrukcije koje omogućuju jednostavan razvoj modela. Vrlo često imaju i odredbe za grafiku i animaciju koje mogu pomoći u vizualizaciji sustava koji se simulira. Simulacija pruža naznaku optimalne strategije. U nekom smislu to je postupak pokušaja i pogrešaka jer se eksperimentira s raznim strategijama koje izgleda imaju smisla i promatraju se objektivni rezultati koje simulacijski model daje kako bi se procijenile zasluge svake strategije. Ako je broj varijabli odluke vrlo velik, tada se čovjek mora nužno ograničiti na neki njihov podskup za analizu, a moguće je da odabrana konačna strategija možda nije optimalna. Međutim, cilj je često pronaći dobru strategiju, a ne nužno i najbolju, a simulacijski modeli vrlo su korisni u pružanju dobrih rješenja donositeljima odluka (Rajgopal, 1997:39)

## 5. PROGRAMSKI (SOFTWARE) PAKETI ZA OPTIMIZIRANJE

Softveri za optimizaciju koriste se u širokom spektru aplikacija, uključujući i temeljne znanosti, inženjerstvo, operacijsko istraživanje i ekonomije. Rođenje moderne optimizacije datira izumom Georgea Dantziga simplex algoritmom za linearno programiranje u kasnim 1940-ima. Ova izuzetno učinkovita metoda i danas je osnova većine kodova linearnog programiranja. Kodovi linearnog programiranja troše mnogo više računalnih ciklusa nego kodovi bilo kojeg drugog softverskog paketa za optimizaciju. Razlozi su dijelom povijesni, a dijelom praktični. Čak i kad je temeljna aplikacija zapravo nelinearna, kao što je to često slučaj, linearni model je dovoljan da donese korisne rezultate, a nedostupnost velikog broja podataka s povezanim problemom čini upotrebu nelinearnog modela nepotrebno sofisticiranim u ovom slučaju (Wright, 1999:2-3).

″Mnogobrojni i različiti softverski programi predstavljaju učinkovitu logistiku u primjeni operacijskih istraživanja u najsloženijim pothvatima temeljnih, primijenjenih i razvojnih istraživanja″ (Zelenika, 2015:46). Prelazak na rješavanje problema s računalnom potporom bilo je neizbježno obzirom na sve zahtjevnije zadatke operacijskih istraživanja. Standardni tradicionalni načini rješavanja problema uključivali su ljudski faktor koji nije u potpunosti osposobljen za rješavanje svih postavljenih problema, uz to, često se znaju dogoditi neizbježne greške, dok su računalni softveri opremljeni za takve, za čovjeka zahtjevne probleme, riješe automatski i bez grešaka.

Čak i tamo gdje organizacija ima softver za cijelu tvrtku, transakcijski podaci koji se čuvaju u njezinim bazama podataka strukturirani su tako da optimiziraju poslovne funkcije. Ove baze podataka sadrže mnoštvo podataka koje organizacijama mogu pomoći u određivanju najboljih strategija optimizacije poslovanja. To se može postići modernim tehnikama analize podataka koje koriste algoritme za prepoznavanje obrazaca u nepovezanim i nestrukturiranim skupovima podataka koji podržavaju donošenje odluka na temelju podataka. Neki čak koriste matematičke mogućnosti poput linearnog programiranja kako bi pružili apsolutni najbolji slučaj za tvrtku koja se optimizira. Zahvaljujući mogućnostima naprednog softvera za modeliranje, moguće je pripremiti matematički model poslovanja. Jednom pripremljen, model se provjerava pomoću povijesnih podataka kako bi se potvrdila njegova cjelovitost. Zatim, koristeći strukturirane i nestrukturirane podatke dostupne tvrtki, softver za rješavanje optimizacije identificira najbolje odluke i potrebne organizacijske promjene za optimizaciju

poslovanja. Budući da je model provjeren, odgovori imaju vjerodostojnost i ne uključuju osobne pristranosti. (Logic, 2019)

Tvrtke u logistici i opskrbi industrije koriste brojne softverske pakete kako bi optimizirali svoje poslovanje. Neka od rješenja za optimizaciju su (Mengistu, 2013:23):

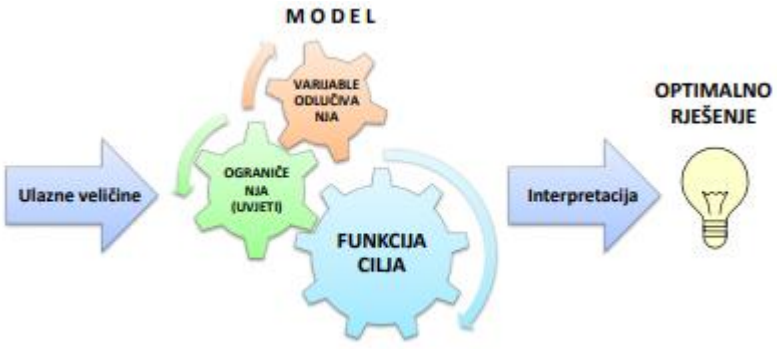
- LINGO – sveobuhvatan alat koji je dizajnirao Lindo Systems Inc. za izradu građevinskih i rješavanja linearnih, nelinearnih (konveksnih / ne konveksnih / globalnih), kvadratnih, kvadratno ograničenih, drugorazrednih, stohastičkih i integriranih optimizacijskih modela brže, jednostavnije i učinkovitije;
- AIMMS – koristi ga TNT Express, u fazi implementacije ovaj softver spasio je tvrtku i uštedio 290 milijuna dolara;
- Ortec softver za planiranje i optimizaciju – koriste tvrtke kao što je DHL, NAGEL i DB SCHENKER za poboljšanje usmjeravanja i slanja vozila uštedjevši ogromne troškove procesa,
- SAS / OR;
- JDA – sveobuhvatan set alata za linearno programiranje dizajniran za analizu ključnih čimbenika i strategije optimizacije, povezan s radom opskrbe do početka do kraja mreže, uključujući troškove, kapacitet, lokacije, a zatim optimizira i mrežu kako bi se postigao najniži ukupni trošak uz ostvarenje najveće moguće dobiti;
- SAP – pomaže organizacijama u određivanju optimalnih vremenskih promjena u zalihama za svaku stavku na svakom mjestu u lancu opskrbe.

## 6. LINEARNO PROGRAMIRANJE

Stvaranje tehnologije, metode operacijskih istraživanja postaju sve sofisticiranije, jednostavnije ih je koristiti, vrijeme unošenja podataka i dobivanja rezultata je skraćeno, a uz to, i metode optimiranja su usavršene, te su osmišljene i neke nove. Izbor metode optimiranja ovisi o cilju koji je postavljen i obilježjima koja se unose. Metoda koja je najčešće korištena i najviše usavršena je metoda optimiranja linearnih sustava, odnosnu, drugim nazivom, linearno matematičko programiranje.[5] Prema Zelenika (2015:48) ″s matematičkog stajališta pod linearnim programiranjem podrazumijeva se optimiziranje jedne funkcije cilja uz izvjesna ograničenja koja limitiraju veličine varijabli. Na načelima linearnog programiranja razvili su se različiti modaliteti simpleks metoda koji omogućuju iznalaženje optimalnih rješenja, modela, procesa različitih problema linearnog programiranja u primarnim, sekundarnim, tercijarnim, kvartarnim i kvintarnim djelatnostima.″

″Matematički modeli linearnoga programiranja ili linearni modeli (Slika 2.) imaju gore navedena svojstva, a sastoje se od sljedećih triju sastavnica (Stanković, Pašagić – Škrinjar, 2015:14):

- varijabla odlučivanja,
- funkcije cilja,
- ograničenja.″




Slika 2.: Matematički model linearnog programiranja

Izvor: Stanković, Pašagić – Škrinjar, 2015:15

[5] Optimiranje. Hrvatska enciklopedija. Dostupno na. https://www.enciklopedija.hr/natuknica.aspx?ID=45345, (10.09.2020.)

### 6.1. Oblik linearnog programiranja

Linearna funkcija ima sljedeći oblik:

$$a_0 + a_1 x_1 + a_2 x_2 + a_3 x_3 + \ldots + a_n x_n = 0$$

Gdje $a_{i,\, i=}$ 0,1, …. n predstavljaju koeficijente koji se nazivaju i parametri, a $x_i$, i = 0, 1, … n predstavljaju varijable. Varijable odluka u linearnom programu skup su veličina koje se moraju definirati i odrediti da bi se riješio problem. Linearni program je riješen kada su pronađene najbolje vrijednosti varijabli. Cilj je optimiziranje rezultata. Obično je cilj maksimizirati ili minimizirati neku brojčanu vrijednost koja bi, na primjer, mogla biti trošak prijevoza, dobit, količina proizvedenog proizvoda itd (Mengsitu, 2013:17).

Da bi se neki problem mogao smatrati problemom linearnog programiranja on mora imati slijedeće karakteristike:

1. Funkcija koju želimo optimizirati (maksimizirati ili minimizirati) mora biti linearna. To znači da je moguće napisati je u obliku: z = a1x1 + … + anxn gdje su a1, … , an konstante (npr. z = x1 2 x2 nije linearna funkcija) Tu funkciju zvati ćemo kriterijalna funkcija a varijable x1, … , xn varijable odlučivanja.
2. Vrijednosti varijabli odlučivanja moraju zadovoljavati skup ograničenja. Ta ograničenja moraju biti izražena u obliku linearnih jednadžbi ili nejednadžbi.
3. Neke varijable odlučivanja mogu imati ograničenje nenegativnosti (npr. xi ≥ 0).[6]

Problemi linearnog programiranja mogu se riješiti softverom. Dodatak za rješavanje programskog jezika Microsoft Excel dobar je primjer. Solver se može primijeniti za rješavanje mali problema, a koristi se među ljudima koji rade u logistici i gotovo svim ostalim industrijama.

[6]Operacijska istraživanja. Dostupno na. https://www.veleri.hr/files/datotekep/nastavni_materijali/k_promet_2/Operacijska_istrazivanja_1._dio.pdf, (11.09.2020.)

## 6.2. Primjer transportnog linearnog programiranja

Transportni problem ili model transporta je specijalni slučaj linearnog programiranja.

Kod transportnog problema se radi o tome da se neko homogeno dobro u količini $ai$ , i=1,2,…,m prenese s ishodišnog mjesta $Ii$ , i=1,2…,m na odredišno mjesto $Oj$ , j=1,2,…,n , uz minimalne troškove.

Pri tome se polazi od toga da su transportni troškovi po jedinicama konstanti (ne variraju) s količinom koja se transportira od mjesta $Ii$ do mjesta Oj te iznose $Cij$, i=1,2…,m; j=1,2,…,n.

Količina koja se transportira iz mjesta$Ii$do mjesta O je $xij$, i=1,2…,m; j=1,2,…,n.[7]

### *6.2.1. Postavljanje problema*

Poduzeće mora transportirati proizvode iz dva pogona P1 i P2 do tri skladišta S1, S2 i S3. Pogoni raspolažu sa kapacitetom od 20 proizvoda tjedno, a skladišta mogu primiti 12, 12, 16 komada tjedno. Potrebno je napraviti plan transporta robe od pogona do skladišta u najkraćem roku i uz minimalne troškove. Vrijeme potrebno da kamion s robom pređe od pogona do skladišta je dano u tablici.

Tablica 1.: Vrijeme vožnje od pogona do skladišta

| Pogon | *S1* | *S2* | S3 | |
|---|---|---|---|---|
| *P1* | 30 | 60 | 20 | 20 |
| *P2* | 40 | 10 | 15 | 20 |
| | 12 | 12 | 16 | |

Izvor: izrada autora prema predavanjima sa kolegija Kvantitativne metode za poslovno odlučivanje (14.09.2020.)

Sljedeći korak u sastavljanju plana optimalnog vremena transporta uz najmanje troškove je postavljanje varijabli odlučivanja.

Varijable odlučivanja u zadatku:

$X_{11}$-količina proizvoda koja se transportira iz pogona P1 do skladišta S1

$X_{12}$ -količina proizvoda koja se transportira iz pogona P1 do skladišta S2

$X_{13}$-količina proizvoda koja se transportira iz pogona P1 do skladišta S3

$X_{21}$-količina proizvoda koja se transportira iz pogona P2 do skladišta S1

$X_{22}$-količina proizvoda koja se transportira iz pogona P2 do skladišta S2

[7]bilješke s predavanja

$X_{23}$-količina proizvoda koja se transportira iz pogona P2 do skladišta S3

Postavljene varijable odlučivanje potrebno je znati iščitati, a glasile bi:
$C_{11}$-jedinična cijena transporta iz pogona P1 do skladišta S1 iznosi 30 NJ
$C_{12}$-jedinična cijena transporta iz pogona P1 do skladišta S2 iznosi 60 NJ
$C_{13}$-jedinična cijena transporta iz pogona P1 do skladišta S3 iznosi 20 NJ
$C_{21}$-jedinična cijena transporta iz pogona P2 do skladišta S1 iznosi 40 NJ
$C_{22}$-jedinična cijena transporta iz pogona P2 do skladišta S2 iznosi 10 NJ
$C_{23}$-jedinična cijena transporta iz pogona P2 do skladišta S3 iznosi 15 NJ

Sljedeći korak u postavljanju transportnog problema je napraviti dodatnu Excel tablicu sa definiranim varijablama odlučivanja, odnosno prikazati transportni problem.

Tablica 2. Transportni problem

| Pogon | S1 | S2 | S3 | | |
|---|---|---|---|---|---|
| P1 | x11 | x12 | x13=20-x11-x12 | 20 | ponuda |
| P2 | x21=12-x11 | x22=12-x12 | x23=-4+x11+x12 | 20 | potražnja |
| | 12 | 12 | 16 | | |

Izvor:izrada autora prema predavanjima sa kolegija Kvantitativne metode za poslovno odlučivanje (14.09.2020.)

*6.2.2. Funkcija cilja*

Ono što se može iščitati iz postavljenog tabličnog problema je funkcija cilja. Funkcija cilja je minimizirati troškove transporta, a u isto vrijeme skratiti i vrijeme dostave. Ponovno, dobivene rezultate je potrebno znati pročitati, a funkcija cilja glasi:

- minT=30x11+60x12+20x13+40x21+10x22+15x23
- minT=30x11+60x12+20*(20-x11-x12)+40*(12-x11)+10*(12-x12)+15*(-4+x11+x12)
- minT=30x11+60x12+400-20x11-20x12+480-40x11+120-10x12-60+15x11+15x12
- minT=-15x11+45x12+940

Konačna funkcija cilja glasi:

*Minimalni trošak -15 $X_{11}$ + 45 $X_{12}$ + 940*

## 7. DEFINIRANJE PROBLEMA I RIJEŠENJE

Optimizacija je ona disciplina unutar primijene matematike koja se bavi optimizacijom problema, ili takozvanim matematičkim programima. U optimizacijskom problemu ili matematičkom programu, problem se nastoji minimizirati (ovisno o kojoj se varijabli radi) ili maksimizirati (ako se radi o dobiti).

Iako često ne primjetno, operacijsko istraživanje nalazi se u većini poslovanja. Metode za optimiranje mogu se koristiti za nebrojno puno situacija, a menadžeri moraju pronaći prema varijablama odlučivanja koja će sadržavati najviše informacija za rješavanje problema.

U ovom odjeljku biti će navedeni primjeri uspješnih stvarnih aplikacija operativnih istraživanja. Ovi primjeri bi trebali stvoriti bolje razumijevanje za različite vrste problema koje operacijska istraživanja mogu riješiti, kao i za način na koji može stvoriti uštedu.

Tablica 3.: Odabrani stvarni slučajevi korištenja metoda optimiziranja

| Organizacija | Primjena | Godišnja ušteda |
|---|---|---|
| Electric Power Research Institute | Postavljanje zaliha nafte i ugljena za električnu uslugu s ciljem uravnoteženja troškova zaliha | $59 milijuna |
| Citgo Petroleum Corp. | Optimizacija pročišćavanja, ponude, distribucije i komercijalizacije proizvodnih operacija | $70 milijuna |
| IBM | Integracija nacionalnog popisa rezervnih dijelova za poboljšanje servisne podrške | $20 milijuna + $250 milijuna u inventaru |
| Time Inc. | Upravljanje distribucijskim kanalima časopisa | $3,5 milijuna dodatnog profita |
| Vojska US | Logističko planiranje operacija | Ne može se procijeniti |
| Samsung Electronics | Smanjuje vrijeme proizvodnje i količine proizvoda na zalihama | $200 milijuna dodatnog profita |
| Welch'c | Optimizira upotrebu i kretanje sirovina | $150,000 |
| Federal Express | Logističko planiranje otpreme | Ne može se procijeniti |

| | | |
|---|---|---|
| Procter and Gamble | Redizajn sjevernoameričke proizvodnje | $200 milijuna |

Izvor: izrada autora prema Mengistu, 2013:24-25

### 7.1. Harris Corporation

Harris Corporation je američka tehnološka tvrtka, pružatelj usluga informacijske tehnologije koja je proizvodila bežičnu opernu, radio stanice, elektroničke sustave, opremu za noćni vid i antene za upotrebu u vladinom, obrambenom i komercijalnom sektoru. Specijalizirali su se za nadzorna rješenja i elektroničko ratovanje.

Tvrtka Harris Corporation nekoliko je godina bila poprilično malo poduzeće koje se bavilo tržišnim nišama u zrakoplovnoj i obrambenoj industriji gdje je konkurencija bila minimalna. Međutim, 1988. godine donesena je strateška odluka o kupnji linije poluvodičkih proizvoda i proizvodnih pogona General Electronica. To je odmah povećalo veličinu operacija i linija proizvoda tvrtke Harris za otprilike tri puta, što je još važnije, Harris je kapitulirao u komercijalna tržišna područja poput automobila i telekomunikacija gdje je konkurencija bila jaka. S obzirom na novu raznolikost proizvodnih linija i strahovito povećanje složenosti planiranja proizvodnje, Harris je teško ispunjavao raspored isporuka i zadržao konkurentnost iz financijske perspektive, jasno je da je bio potreban bolji sustav (Rajgopal, 1997:40).

U fazi orijentacije bilo je ponuđeno nekoliko rješenja, međutim, najbolje rezultate je dao IMPReSS sustav za automatizirano planiranje proizvodnje i sustav kvotiranja isporuke za cijelu proizvodnu mrežu. Sustav je impresivna kombinacija tehnika temeljenih na optimizaciji. Djeluje razbijanjem cjelokupnog problema na manje probleme kojima se više može upravljati uporabom heurističkog pristupa razgradnji. Matematički modeli unutar problema rješavaju se linearnim programiranjem zajedno s konceptima iz planiranja materijalnih zahtjeva. Cijeli sustav povezan je sa sofisticiranim bazama podataka što omogućuje predviđanje, unos ponuda i unos narudžbi, materijale i dinamičke informacije o kapacitetima. Tvrtka Harris procjenjuje da je ovaj sustav povećao pravovremene isporuke sa 75% na 95% bez povećanja zaliha, pomogao mu je da se sa 75 milijuna dolara gubitaka premjesti na 40 milijuna dolara dobiti godišnje i omogućio učinkovitije planiranje kapitalnih ulaganja (Rajgopal, 1997:40).

### 7.2. Zara

Španjolski proizvođač i maloprodavač odjeće Zara ima opskrbni lanac koju uključuje dva primarna skladišta smještena u Španjolskoj. Skladišta povremeno primaju pošiljke gotove odjeće od dobavljača iz cijelog svijeta, a putem brodova se stvaraju zalihe robe u svakoj trgovini na svijetu, dva puta tjedno. Određivanje točnog broja količine svakog artikla koji bi trebao biti uključen u pošiljku, za svaku od 1500 trgovina širom svijeta bio je izazov za profesionalce. Jedna pošiljka uključuje do 3000 komada odjeće, sa osam različitih veličina. Pronalazak rješenja bio je ključan za Zarinu svakodnevnu poslovnu aktivnost, ali je izazov dosta težak jer je količina relevantnih podataka ogromna, a broj povezanih pošiljki doseže nekoliko milijuna artikala. Odluke  otpremi se također moraju donijeti u roku od nekoliko sati. Alternativni program razvio je tim stručnjaka operacijskom istraživanja koji koristi analitičke metode, uključujući algoritme predviđanja, stohastičku analizu i veliki mješoviti model programiranja. Stvorio se program s različitih tehničkim poteškoćama i ljudskim izazovima. Međutim, razvoj ovog novog postupka dovršen je 2007. godine i implementiran je u sve trgovine svijeta. Pilot pokus proveden je na ograničenom broju poslovnica širom svijeta. Samo financijska korist kroz ostvarenu prodaju može se procijeniti na oko $350 milijuna u 2008. godini. Predviđa se da će ovaj financijski prihod dodatno rasti za 13% u sljedećim godinama (Mengistu, 2013:26)

## 8. ZAKLJUČAK

Nesretna je stvarnost da operacijska istraživanja ima jako veliku količinu negativnog publiciteta. Svojevremeno se na nju gledalo kao na egzotičnu znanost koja nema previše značaja za stvarni svijet, a neki su je kritičari nazvali i skupom tehnikom za potragu problema koji se treba riješiti. Jasno je da je ova kritika neistinita i da postoji mnoštvo dokumentiranih dokaza da su operacijska istraživanja, kada se pravilo primjenjuju i fokusiraju se na problem, od velikog značaja za rješavanje problema i stvaranja prednosti. S druge strane, postoje i dokazi koji upućuju na to da su kritike upućena prema operacijskim istraživanjima često i relativno točne, odnosno, da nisu u potpunosti neutemeljene. To je zato što se operacijska istraživanja često ne primjenjuju kako bi trebala, uz krivnju ljudskog faktora. Ljudski faktor često krivo shvati da su ova istraživanja metoda, a ne cjeloviti sustavni postupak. Konkretno, naglasak je bio na naglašenom koraku modeliranja i rješenja, vjerojatno zato što oni očito nude najinteligentniji izazov. Međutim, od presudnog je faktora ovdje zadržati fokus usmjeren na probleme. Krajnji cilj operacijskih istraživanja je provesti rješenje problema koji se analizira. Drugi razlog zašto se smatra da operacijska istraživanja ne donose dobre rezultate i skupa su investicija, je što je rezultate iz istraživanja potrebno znati pročitati. Mnogi analitičari su loši u priopćavanju rezultata u terminima koji mogu razumjeti drugi partneri u procesu koji možda nemaju veliku matematičku sofisticiranost ili formalno obrazovanje.

Ako se ovaj postupak ne vodi pažljivo, često rezultira minimalnim dohotkom i manje nego zadovoljavajućim rezultatima zbog poteškoća koje vanjski savjetnici imaju u stvarnom razumijevanju posla. To ne znači da optimizacija poslovanja ne funkcionira, niti da nije važna. Zapravo, svako bi poduzeće trebalo neprestano tražiti načine za poboljšanje učinkovitosti, smanjenje otpada i optimizaciju resursa kao dio svoje stalne poslovne prakse. Poslovna optimizacija najbolje funkcionira ako je pokrenuta interno i podržana kvalitetnim i odgovarajućim softverom za podršku odlukama koji pomaže rukovoditeljima utvrditi koja od mnogih mogućih strategija poslovne optimizacije nudi povrat.

Krajnji zaključak je kako projekti operacijskih istraživanja i metode optimiranja mogu stvoriti uspješne rezultate i rješenja na probleme ako im se posveti dovoljno pažnje. Svaki korak procesa se mora posebno sagledati i biti maksimalno uključen u postavljanje varijabli kako bi se dobili cjeloviti rezultati, a potrebno je i znati pročitati dobivene informacije te ih predstaviti u razumljivom obliku krajnjim korisnicima. Samo tako ljudi će prepoznati potpuni potencijal metoda optimiranja.

## LITERATURA

### Knjige i stručni članci:


1. Barković, D. (1994.). Operacijska istraživanja u službi menadžera. Ekonomski vjesnik. Vol. 1. No. 7. str. 111-116
2. Barković, D. (1997). Operacijska istraživanja. Sveučilište J. J. Strossmayera u Osijeku. Ekonomski fakultet Osijek. Osijek.
3. Crnošija, P. (2003). Primjena metoda optimiranja za određivanje linearnog kontinuiranog modela sustava regulacije parne turbine. Hrvatski komitet međunarodnog vijeća za velike električne sisteme. Zagreb. str. 177-188
4. Mengistu,S.(2013.). An insight in to operations research. Application in logistics and supply chain management. Helsinki Metropolia Universty of Applied Sciences
5. Ragopal, J. (1997.). Principles and applications of operations research. Maynards industrial engineering handbook, 5th Edition, str. 17-44
6. Stanković, R., Škrinjar, Pašagić, J. (2015.). Logistika i transportni modeli. Autorizirana predavanja. Fakultet prometnih znanosti. Zavod za transportnu logistiku. Zagreb
7. Zelenika, R. (2016.). Metode operacijskih istraživanja u kaleidoskopu obrazovnih i znanstvenih industrija. Naše more. Vol. 63. No. 1.str. 44-52
8. Wright, S. J. (1999.). Optimization Softver Packages. Mathematicsand Computer Science Division. Argonne National Laboratory


### Internet izvori:


9. Logic, R. (2019.). Business optimization: What it means and why you need it. Dostupno na. https://www.riverlogic.com/blog/business-optimization-what-it-means-and-why-you-need-it, (12.09.2020.)
10. Operacijska istraživanja. Dostupno na. https://www.veleri.hr/files/datotekep/nastavni_materijali/k_promet_2/Operacijska_istrazivanja_1._dio.pdf, (11.09.2020.)
11. Optimiranje. Hrvatska enciklopedija. Dostupno na. https://www.enciklopedija.hr/natuknica.aspx?ID=45345, (10.09.2020.)
12. Top 6 methods used in operation research. Dostupno na. https://www.businessmanagementideas.com/personnel-management/operation-research/top-6-methods-used-in-operation-research/6727, (11.09.2020.)

**POPIS SLIKA**

Slika1.: Postupak optimiranja ……4

Slika2.: Matematički model linearnog programiranja…...…….…..13

**POPIS TABLICA**

Tablica1. Vrijeme vožnje od pogona do skladišta ……...15

Tablica 2. Transportni problem ……16

Tablica 3.: Odabrani stvarni slučajevi korištenja metoda optimiziranja ……..17