Optimizacija distribucijske mreže u tvrtki

Mihaljević, Ana

Master's thesis / Diplomski rad

2018

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Transport and Traffic Sciences / Sveučilište u Zagrebu, Fakultet prometnih znanosti**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:119:520549

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**



Repository / Repozitorij:

Faculty of Transport and Traffic Sciences - Institutional Repository







SVEUČILIŠTE U ZAGREBU

FAKULTET PROMETNIH ZNANOSTI

Ana Mihaljević

OPTIMIZACIJA DISTRIBUCIJSKE MREŽE U TVRTKI

DIPLOMSKI RAD

Zagreb, 2018.

SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI
POVJERENSTVO ZA DIPLOMSKI ISPIT

Zagreb, 24. travnja 2017.

Zavod: **Zavod za transportnu logistiku**
Predmet: **Distribucijska logistika I**

DIPLOMSKI ZADATAK br. 4186

Pristupnik: **Ana Mihaljević (0135228332)**
Studij: Inteligentni transportni sustavi i logistika
Smjer: Logistika

Zadatak: **Optimizacija distribucijske mreže u tvrtki**

Opis zadatka:

U radu je potrebno izvršiti analizu distribucijske mreže odabrane tvrtke po kriteriju robnih tokova te raspoloživih skladišnih i prijevoznih resursa. Osim toga, potrebno je prikazati osnovne modele za optimizaciju distribucijske mreže, te primjenom izabranog modela uskladiti kapacitete promatranog distribucijskog sustava.

Zadatak uručen pristupniku: 28. travnja 2017.

Mentor:

prof. dr. sc. Kristijan Rogić

Predsjednik povjerenstva za diplomski ispit:

Sveučilište u Zagrebu

Fakultet prometnih znanosti

DIPLOMSKI RAD

OPTIMIZACIJA DISTRIBUCIJSKE MREŽE U TVRTKI

OPTIMITIZATION OF DISTRIBUTION NETWORK IN COMPANY

Mentor: prof. dr. sc. Kristijan Rogić

Student: Ana Mihaljević

JMBAG: 0135228332

Zagreb, svibanj 2018.

OPTIMIZACIJA DISTRIBUCIJSKE MREŽE U TVRTKI

SAŽETAK

Strategija tvrtke po pitanju dizajna distribucijske mreže jedno je od najvažnijih pitanja cjelokupne politike tvrtke. Troškovi koji pri distribuciji nastaju mogu zauzimati veliki dio u sveukupnim troškovima te je stoga posebnu pažnju potrebno posvetiti optimizaciji distribucijske mreže. Imati što manje troškove a što veću kvalitetu usluge cilj je svake tvrtke, neovisno o njezinoj djelatnosti. Nakon analize određene distribucijske mreže, u radu će se prikazati najprije matematički modeli a zatim i optimalna rješenja u programskom alatu Solver.

.

KLJUČNE RIJEČI: distribucijska mreža; optimizacija; matematički modeli; opskrbni lanac

SUMMARY

The company's strategy of designing the distribution network is one of the most important issues of the company's overall policy. Costs that are generated at distribution can take up a large part in overall costs, and therefore special attention should be paid to the optimization of the distribution network. Having as little cost as possible and the highest quality of service is the goal of every company, regardless of its business. After analyzing a particular distribution network, the paper will first outline the mathematical models and then the optimum solutions in the Solver programming tool for a specific problem.

KEY WORDS: distribution network; optimization; mathematical models; supply chain

1. UVOD 1
2. ULOGA DISTRIBUCIJE U OPSKRBNOM LANCU 3
2.1. OPSKRBNI LANAC 3
2.1.1. Definicija opskrbnog lanca 3
2.1.2. Faze opskrbnog lanca 4
2.1.2.1. Strategija opskrbnog lanca ili dizajn 4
2.1.2.2. Planiranje opskrbnog lanca 5
2.1.2.3. Operativni rad opskrbnog lanca 5
2.1.3. Razvoj opskrbnog lanca 5
2.1.3.1. Prva revolucija opskrbnog lanca (1910-1920) 6
2.1.3.2. Druga revolucija opskrbnog lanca (1960-1970) 6
2.1.3.3. Treća revolucija opskrbnog lanca (1995-2000) 7
2.2. ULOGA DISTRIBUCIJE U OPSKRBNOM LANCU 7
2.2.1. Definicija distribucije unutar opskrbnog lanca 8
2.2.2. Vrste dizajna distribucijske mreže unutar opskrbnog lanca 10
2.2.2.1. Proizvodno skladište s direktnom dostavom 11
2.2.2.2. Proizvodno skladište s direktnom dostavom i spajanjem proizvoda u tranzitu 12
2.2.2.3. Distribucijsko skladište sa isporukom pošiljaka pomoću posrednika 12
2.2.2.4. Distribucijsko skladište sa isporukom pošiljaka direktno korisniku 13
2.2.2.5. Proizvodno/distribucijsko skladište sa preuzimanjem pošiljaka od strane korisnika 13
2.2.2.6. Trgovinsko skladište sa preuzimanjem pošiljaka od strane korisnika 14
2.3. PRIMJER SUVREMENOG OPSKRBNOG LANCA U MODNOJ INDUSTRIJI 15
3. MOGUĆNOSTI OPTIMIZACIJE DISTRIBUCIJSKE MREŽE PRIMJENOM MATEMATIČKIH MODELA 17
3.1. IZRADA MODELA 17
3.2. MODELI ZA OPTIMIZACIJU DISTRIBUCIJSKE MREŽE 19
3.2.1. Modeli optimizacije u drugoj fazi 20
3.2.1.1. Model s određenim kapacitetom postrojenja 20
3.2.1.2. Model s neodređenim kapacitetom postrojenja 21
3.2.2. Modeli optimizacije u trećoj fazi 22
3.2.3. Modeli optimizacije u četvrtoj fazi 23
3.2.3.1. Model dodjele potražnje proizvodnim postrojenjima 23
3.2.3.2. Model lociranja tvornica i skladišta istovremeno 24
4. ANALIZA POSTOJEĆEG DISTRIBUCIJSKOG SUSTAVA U TVRTKI 27

5. PRIJEDLOG IZGRADNJE OPTIMALNE DISTRIBUCIJSKE MREŽE 31
5.1. MATEMATIČKI MODEL ZADANOG PROBLEMA 31
5.2. POSTAVLJANJE MODELA U PROGRAMSKI ALAT EXCEL SOLVER 33
5.3. OPTIMIZACIJA DISTRIBUCIJSKE MREŽE S UVOĐENJEM OGRANIČENJA ZA UDALJENOST 41
5.4. DODATNO O OPTIMIZACIJI DISTRIBUCIJSKIH PROCESA U TVRTKI 47
6. ZAKLJUČAK 49
POPIS LITERATURE 51
POPIS SLIKA 52
POPIS TABLICA 53

1. UVOD

Prije nego proizvod dođe u ruke korisnika, on prođe veoma dug put. Standardni opskrbni lanci započinju sa jedinim ili više dobavljača koji imaju zadatak opskrbiti proizvođača odgovarajućim sirovinama. Nakon što proizvođač završi sa proizvodnjom, proizvod još mora proći manji ili veći broj sudionika opskrbnog lanca kako bi došao do kupca. Pritom se događa transformacija iz sirovine u gotovi proizvod.

Proizvodi moraju biti dostupni u pravo vrijeme, na pravom mjestu i u pravoj količini. Kako bi osigurale operativnu učinkovitost, tvrtke moraju organizirati distribucijske mreže, koje se, ovisno o tvrtki, mogu sastojati od jednog ili više skladišta u kojima se proizvodi primaju, skladište i zatim isporučuju u dućane i/ili krajnjim korisnicima. Neovisno o djelatnosti tvrtke, cilj je uvijek ostvariti što manji trošak opskrbnog lanca, pritom održavajući visoku razinu usluge krajnjem korisniku i brzu dostavu. Sa sve većim brojem različitih proizvoda porasla su očekivanja korisnika, i to ne samo po pitanju karakteristika proizvoda nego i po pitanju brzine i sigurnosti dostave.

Zbog sve bržeg razvoja tehnike i tehnologije, svakih se nekoliko godina mora provesti analiza distribucijske mreže te otkriti i ukloniti nedostaci na istoj, a na temelju ponude i potražnje u određenom razdoblju. Najčešće se analize takvog tipa provode kada se želi odrediti broj skladišta u mreži, njihova optimalna lokacija, optimalan broj skladišta u mreži (npr. spajanje skladišta u jedan logistički centar), koji distribucijski centar bi trebao opskrbljivati koje korisnike ili koji bi distribucijski centar trebao skladištiti koje proizvode i slično.

Svrha ovog diplomskog rada je kroz teorijski i praktični dio prikazati kako optimizacija distribucijske mreže može u znatnoj mjeri utjecati na raspon troškova i razine usluge korisniku. Rad je podijeljen u šest dijelova, od kojih se 4 odnose na teorijsko istraživanje, dok su dva napravljena na temelju praktične analize, a to su:

1. Uvod
2. Uloga distribucije u opskrbnom lancu
3. Mogućnosti optimizacije distribucijske mreže primjenom matematičkih modela
4. Analiza postojećeg distribucijskog sustava u tvrtki
5. Prijedlog izgradnje optimalne distribucijske mreže
6. Zaključak

Nakon uvoda, u drugom poglavlju govorit će se najprije o samom opskrbnom lancu, svim njegovim elementima i fazama, kao i sudionicima. Detaljno će se proći kroz sve faze razvoja opskrbnog lanca nakon čega će se poseban dio posvetiti samoj distribuciji unutar njega. Nakon analize nekoliko mogućnosti distribucije unutar lanca, u zadnjem dijelu ovog poglavlja predstavit će se opskrbni lanac jedne tvrtke.

U trećem poglavlju prikazani su matematički modeli kojima se uspješno može pomoći pri optimizaciji distribucijske mreže.

U četvrtom poglavlju na primjeru iz prakse izvršena je analiza distribucijske mreže sa svim podacima potrebnim za optimizaciju.

Peto poglavlje prikazuje rezultate optimizacije distribucijske mreže zadane tvrtke iz prethodnog poglavlja, primjenom matematičkih modela i softverskog alata Solver.

U zaključku su obrađeni najvažniji rezultati istraživanja koji su nastali kombinacijom teorijskog i praktičnog dijela rada.

2. ULOGA DISTRIBUCIJE U OPSKRBNOM LANCU

Situacija na tržištu robe široke potrošnje se značajno promijenila u posljednjih 20 godina. Sa sve bržim razvojem tehnologija i sve većim utjecajem globalizacije, proizvodi na tržištu su postali sve brojniji i sa sve većim brojem različitih karakteristika. Zahtjevi korisnika su se također promijenili, pri čemu su korisnici danas postali sve više zahtjevni, i to ne gledajući samo po karakteristikama proizvoda nego i njegovoj dostupnosti. Danas tvrtke moraju sve veću pozornost posvetiti razvoju opskrbnog lanca kako bi zadovoljili sve zahtjevniju potražnju.

2.1. Opskrbni lanac

U ovom poglavlju proći će sve bitne karakteristike opskrbnog lanca od definicije, dizajna, planiranja, operativnog rada unutar istoga te svih sudionika koji u većoj ili manjoj mjeri služe ispunjenju njegovog krajnjeg cilja: ispunjenja korisnikovog zahtjeva, kao i na sami razvoj opskrbnog lanca kroz povijest.

2.1.1. Definicija opskrbnog lanca

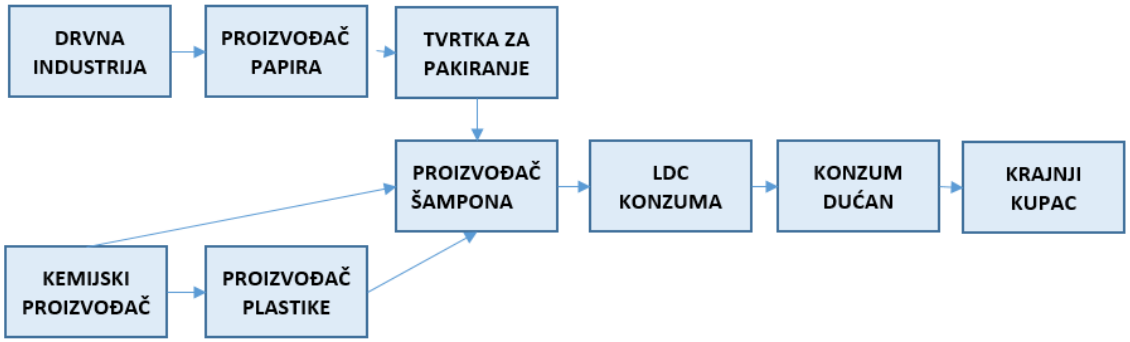
Opskrbni lanac obuhvaća sve aktivnosti uključene u transformaciju proizvoda od razine sirovina do konačne razine, kada proizvodi i usluge dolaze do krajnjeg korisnika. Upravljanje opskrbnim lancem uključuje planiranje, dizajn i kontrolu protoka materijala, informacija i novca kroz opskrbni lanac radi krajnje dostave kupcu na efektivan i efikasan način. [1]

Svaki opskrbni lanac počinje onog trenutka kada korisnik/krajnji kupac iskaže želju za nekim proizvodom. U slijedećem primjeru koristit će se tvrtka Konzum za primjer.

Krajnji korisnik nakon što uvidi potrebu za npr. šamponom ide u trgovinu Konzum kako bi zadovoljio svoju potrebu. U dućanu se proizvod nalazi na polici a tamo je dostavljen iz logističko-distributivnog centra Konzuma. LDC je taj proizvod nabavio od svog dobavljača šampona koji sam ima više dobavljača. Naime, za proizvodnju šampona potrebne su kemikalije, plastika i pakiranje za koje, gore spomenuti dobavljač, mora kontaktirati dobavljače tih komponenti, koji potom moraju svoje komponente nabaviti od drugih dobavljača.

Na Slici 1. se može vidjeti kako cijeli proces izgleda. U namjeri za proizvodnjom šampona, proizvođač će morati nabaviti slijedeće komponente: papir, plastiku i kemikalije. Proizvođač papira će od drvne industrije naručiti određenu količinu celuloze pomoću koje će napraviti papir za naljepnice na ambalaži šampona. Nakon što se to dogodi, tvrtka za pakiranje će taj isti papir u obliku naljepnice staviti na ambalažu šampona. Za tu istu ambalažu,

proizvođač šampona mora kontaktirati proizvođača plastike. Zajednički dobavljač proizvođaču šampona i proizvođaču plastike je kemijski proizvođač koji ispostavlja određene kemikalije. Od proizvođača a po narudžbi Konzuma, šampon se isporučuje na adresu LDC-a. Nakon toga LDC, po narudžbama svakog pojedinačnog dućana isporučuje robu kako bi bila dostupna krajnjem kupcu.



Slika 1. Prikaz opskrbnog lanca

Izvor: prilagodio autor prema izvoru[2]

2.1.2. Faze opskrbnog lanca

Za uspješno funkcioniranje opskrbnog lanca potrebno je donositi niz odluka koje utječu na njegovu efikasnost. Svaka od tih odluka donosi se u tri faze ovisno o učestalosti donošenju svake odluke i vremenskog okvira unutar kojeg ta odluka ima najveći utjecaj. [3]

2.1.2.1. Strategija opskrbnog lanca ili dizajn

Tijekom ove faze donose se sve strateški važne odluke za tvrtku. Tvrtka donosi odluku kakav opskrbni lanac kreirati i kako ga održavati idućih par godina, a na temelju marketinških i cjenovnih planova. Potrebno je odlučiti kakva će biti konfiguracija lanca, kako će resursi biti locirani ili koji će proces biti proveden u kojoj fazi. Osim toga, tvrtka mora odlučiti želi li koristiti vanjske davatelje usluga u pojedinim dijelovima opskrbnog lanca (outsourcing) ili će se opskrbni lanac provoditi unutar tvrtke, lokaciju i kapacitet proizvodnih i skladišnih lokacija, proizvode koji će biti proizvođeni ili skladišteni na različitim lokacijama, načine transporta na različitim transportnim putevima te tip informacijskog sustava koji će biti korišten. Posebno se treba obratiti pozornost na nesigurnost na tržištu prilikom strateškog planiranja jer ovakve strateške odluke se obično donose za duže razdoblje (godine) i svaka promjena nakon kratkog razdoblja bi skupo koštala tvrtku. [3]

2.1.2.2.Planiranje opskrbnog lanca

Konfiguracija opskrbnog lanca je strogo definirana u strateškom dijelu gdje su postavljena određena ograničenja unutar kojih planiranje mora biti napravljeno. Cilj planiranja je maksimizirati profit opskrbnog lanca tijekom kraćeg razdoblja (godina ili četvrtina godine) a samo planiranje započinje prognozom potražnje za izabrano nadolazeće razdoblje za različita tržišta. U ovoj fazi se donose odluke koje se tiču slijedećih tema: koja će tržišta biti opskrbljivana sa kojih lokacija, ugovor s drugim proizvođačima, politika upravljanja zalihama, veličina i cijena marketinške kampanje i promocija cijena. Planiranje utvrđuje parametre unutar kojih bi opskrbni lanac trebao funkcionirati tijekom određenog perioda a tvrtka mora uzeti u obzir nestabilnost potražnje, tečajeve i konkurenciju. Sve fleksibilnosti koje su unutar opskrbnog lanca definirane u strateškoj fazi, tvrtka mora u ovoj fazi iskoristiti za optimizaciju usluge. [3]

2.1.2.3.Operativni rad opskrbnog lanca

Na operativnoj razini, konfiguracija i planiranje opskrbnog lanca su već definirani i odluke koje se donose na ovoj razini podrazumijevaju vremenski horizont od tjedan dana ili čak jedan dan a tiču se individualnih narudžbi korisnika. Tijekom ove faze, tvrtka dodjeljuje zalihe ili proizvodnju individualnim korisnicima, dodjeljuje narudžbi određeni način transporta, postavlja datume kada narudžbe moraju biti ispunjene, određuje raspored kamiona za transport i slično. [3]

Sve tri faze: dizajn, planiranje i operativni rad opskrbnog lanca imaju snažan utjecaj na konačnu profitabilnost i uspjeh.

2.1.3. Razvoj opskrbnog lanca

U četrdesetim i pedesetim godinama prošlog stoljeća, fokus logističkog istraživanja je bio na načinu korištenja mehanizacije (npr. palete ili podizači paleta) kako bi se unaprijedio i ubrzao proces rukovanja materijalom i postigla bolja učinkovitost skladišnog prostora. Do 1950. godine palete su uživale veliku popularnost koja je postala još veća sa razvojem intermodalnih kontejnera zajedno sa brodovima, vlakovima i kamionima za rukovanje s tim kontejnerima. [4]

Pojava osobnih računala 1980-ih je omogućila veći i bolji pristup ali i novu grafičku okolinu za planiranje: fleksibilne proračunske tablice i sučelja temeljena na kartografiji dovela su do značajnijih poboljšanja na području planiranja logistike i opskrbnog lanca.

Možda je najvažniji trend logistike u 1980-ima bio to da su rukovoditelji tvrtki postali

svjesni logistike kao područja gdje su imali priliku znatno poboljšati poslovanje i profit ako su bili spremni uložiti u obučene profesionalce i nove tehnologije. Godine 1985. Nacionalno vijeće za upravljanje fizičkom distribucijom (National Council of Physical Distribution Management) promijenilo je ime u Vijeće za upravljanje logistikom (Council of Logistics Management - CLM). Razlog promjene imena je bio "održavati razvojnu disciplinu koja uključuje integraciju ulaznih, izlaznih i obrnutih tokova proizvoda, usluga i povezanih informacija". Prije toga, logistika je bila pojam koji je korišten gotovo isključivo za opisivanje potpore vojnih pokreta.

Logističkom rastu dodatno je pogodovao razvoj sustav Enterprise Resource Planning (ERP) sustava razvijenog na krilima prijašnjeg uspjela MRP-a (Materiral Resource Planning) a kao rezultat želje za integracijom višestrukih baza podataka koje su postojale u gotovo svim tvrtkama. ERP softveri značajno povećavaju potrebu za boljim planiranjem i integracijom među logističkim komponentama te nude ogroman napredak u dostupnosti i točnosti podataka.[4]

U razdoblju do 2000.godine razvoj opskrbnog lanca prošao je kroz tri faze revolucije.

2.1.3.1.Prva revolucija opskrbnog lanca (1910-1920)

Prvu veću revoluciju u razvoju opskrbnog lanca napravila je tvrtka Ford Motor Company kada su uspjeli napraviti čvrsto integriran opskrbni lanac. Tvrtka je posjedovala svaki dio lanca, od najmanjeg do najvećeg dijela potrebnog za izradu automobila, i kroz taj čvrsto integrirani lanac, omogućili su izradu od željeza do gotovog automobila u 81 sat. Međutim, njihov opskrbni lanac, iako visoko efikasan, nije bilo fleksibilan te se nije mogao nositi sa širokim rasponom proizvoda. Tvrtka General Motors, s druge strane, kreiranju opskrbnog lanca pristupila je s većim razumijevanjem potražnje te je imala veću paletu vozila različitih modela i boja. Njihov opskrbni lanac nasuprot onome tvrtke Ford, zahtijevao je manje vremena za promjene i najvažnije, nije trebao tako velike razine zaliha u lancu. [1]

2.1.3.2.Druga revolucija opskrbnog lanca (1960-1970)

Na kraju prve revolucije, proizvodna industrija je doživjela mnoge promjene ponajprije po pitanju varijabilnosti proizvoda i što manje razine zaliha istih. Takve promjene morale su rezultirati fleksibilnijim i efikasnijim lancem opskrbe. Prva koja se s time uspješno suočila je bila tvrtka Toyota Motor Company koja je svoj opskrbni lanac temeljila na kratkim vremenima spajanja proizvoda i dugoročnim partnerstvima sa dobavljačima. Skup komponenata je nabavljan od većeg broja dobavljača koji su bio dio takozvanog keiretsu sustava, a finalno sklapanje proizvoda događalo se u Toyotinoj tvornici. Dobavljači su se redom nalazili u blizini

tvornice pa je taj pristup omogućio Toyoti smanjenje vremena spajanja proizvoda sa nekoliko sati na nekoliko minuta. Ovaj princip je danas više poznat kao Lean menadžment.

Kao i svaki sustav, ni ovaj nije bio idealan. Dugoročna obaveza prema dobavljaču često je znala rezultirati partnerstvom s dobavljačem koji s vremenom nije više mogao isporučiti istu razinu usluge. Postepeno, Toyota ali i ostale japanske tvrtke su svoje tvornice otvarale širom svijeta što bi po ovom sustavu značilo i povlačenje dobavljača sa sobom. Srećom, sa razvojem elektronske razmjene informacija (EDI) bilo je moguće integrirati više dobavljača bez njihova preseljenja blizu proizvodne tvornice. [1]

2.1.3.3.Treća revolucija opskrbnog lanca (1995-2000)

Od prve revolucije do treće, tvrtke su napredovale od jediničnog proizvoda do visoke varijabilnosti proizvoda te od visoke varijabilnosti do potpune prilagodbe korisniku. Razvoj informacijskih tehnologija, tvrtka Dell Computers iskoristila je kako bi dozvolila svojim korisnicima konfiguraciju njihovih osobnih računala, te isto to nastavila sa proizvodnim i distribucijskim tvrtkama. Za razliku od svog prethodnika Toyote, tvrtka Dell izbjegavala je dugoročne veze s dobavljačima nego se koncentrirala na srednjoročni odnos sa istima, držeći tako dobavljače uvijek na nekoj vrsti testa. Zbog tehnološkog razvoja, tvrtka je bila u mogućnosti integrirati se s dobavljačima elektronski, čak i ako su samo srednjoročno povezani. Politika naručivanja tvrtke Dell značajno se razlikovala od prethodnih. Naručivanje su provodili na temelju stvarnih narudžbi kupaca a ne pomoću predviđanja potražnje, što je značajno smanjilo zalihe. U ovom razdoblju revolucije tvrtke su napredovale od vertikalno integriranih tvrtki preko dugoročnih partnerstva sa sudionicima opskrbnog lanca do " labavijih" veza u mreži. [1]

Najveću i najširu uporabu termin opskrbni lanac je doživio sa razvojem globalizacije. Kao primjer može se navesti kako su Sjedinjene Američke Države (SAD) uvozile iz Kine 1995.godine robe u vrijednosti 45 milijardi dolara, dok je taj iznos 2006. premašio 280 milijardi. S globalizacijom logističke strategije se moraju razvijati imajući u vidu kompleksne mreže koje uključuju mnogo sudionika iz različitih država sa različitom kontrolom.[4]

2.2. Uloga distribucije u opskrbnom lancu

Između svakog sudionika opskrbnog lanca u svakoj fazi odvija se distribucija: sirovine i komponente se kreću od dobavljača do proizvođača, a gotovi proizvodi se kreću od proizvođača preko trgovaca do krajnjih korisnika. Može se donijeti zaključak kako je distribucija veoma važan element politike upravljanja opskrbnog lanca. U narednom dijelu rada prikazat će se

utjecaj distribucije i njezinih čimbenika na kreiranje opskrbnog lanca, različite verzije distribucijske mreže kao i primjeri iz prakse.

2.2.1. Definicija distribucije unutar opskrbnog lanca

Odgovarajuća distribucijska mreža može u značajnoj mjeri utjecati na ostvarivanje različitih ciljeva opskrbnog lanca počevši od niskih troškova do visoke odgovornosti lanca.

Međunarodna trgovačka komora (International Chamber of Commerce – ICC) među prvima je dala definiciju distribucije koja glasi: „Distribucija je faza koja slijedi proizvodnju dobara od trenutka njihove komercijalizacije do isporuke potrošačima. Ona obuhvaća razne aktivnosti i operacije koje osiguravaju da se roba stavi na raspolaganje kupcima, bilo da se radi o prerađivačima ili o potrošačima, olakšavajući izbor, kupnju i upotrebu robe.“ [5]

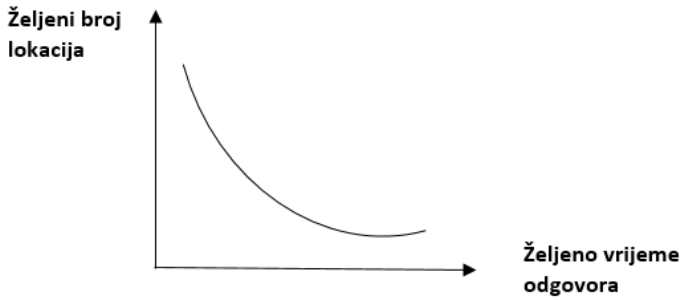
Distribucija predstavlja veoma važan čimbenik u profitabilnosti tvrtke jer svojim utjecajem na opskrbni lanac utječe i na njegove troškove ali i na sveukupni doživljaj korisnika, te kao takva mora ispuniti slijedeće zadatke: [5]

1. Skraćenje vremena i puta potrebnog da roba ili usluga stigne od mjesta proizvodnje do mjesta potrošnje
2. Povećanje konkurentnosti robe
3. Vremensko i prostorno usklađenje proizvodnje i potrošnje
4. Programiranje proizvodnje prema zahtjevima (potrebama) potrošača
5. Plasman novih proizvoda ili usluga na tržištu
6. Stvaranje i mijenjanje navika potrošača

Vrijeme odgovora na narudžbu, bogat asortiman različitih proizvoda te njihova dostupnost u trenutku kada narudžba stigne, brzina i kvaliteta proizvoda plasiranih na tržište kao i manipuliranje robe sa povratom su sve aspekti koji utječu na kreiranje korisnikovog mišljenja o proizvodu odnosno proizvođaču.

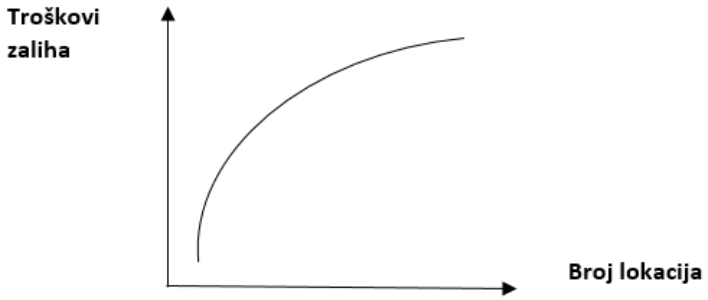
Iako je logična pretpostavka kako svi korisnici žele najvišu moguću razinu usluge unutar svih ovih dimenzija, praksa je pokazala kako to nije slučaj. Istraživanja iz 2006. godine su pokazala kako su kupci spremni čekati na dulje vrijeme isporuke prilikom online naručivanja na Amazon.com nego se uputiti u bliži dućan tvrtke Border za istu knjigu. Korisnici su ocijenili bogatiji asortiman različitih proizvoda na Amazonu boljim od bržeg odgovora na potražnju kod tvrtke Border. Distribucijska mreža Amazona koncipirana je na taj način da se sastoji od manjeg broja lokacijskih skladišta većih u kapacitetu, dok tvrtka Border ima veći broj dućana koji iziskuju veće troškove držanja zaliha. Odnos tih parametara prikazan je na slici 3. S druge strane,

s većim brojem prodajnih lokacija ukupnog broja oko 400 u odnosu na 6 lokacijskih skladišta tvrtke Amazon, Border ima brže vrijeme odgovora na zahtjeve kupca. Odnos tih parametara je prikazan na slici 2.[3]



Slika 2. Odnos između željenog vremena odgovora i broja lokacija skladišta

Izvor: Prilagodio autor iz izvora [6]



Slika 3. Odnos između broja lokacija skladišta i troškova zaliha

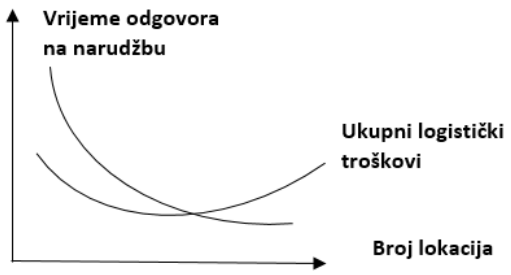
Izvor: Prilagodio autor iz izvora [6]

Kako bi se smanjili troškovi zaliha, tvrtke vrše konsolidaciju i centralizaciju svojih lokacija skladišta. Na primjeru gore navedene dvije tvrtke, Amazon je sa svojih 6 skladišta uspio napraviti koeficijent obrtaja oko 12, dok je Border uspio obrnuti svoje zalihe samo dva puta po

godini.

U slučaju transportnih troškova razlikuju se dvije vrste: ulazni troškovi dovođenja materijala u proizvodnju i izlazni troškovi slanja materijala iz tvornice. Izlazni troškovi imaju tendenciju biti veći nego ulazni. U primjeru Amazona, skladište dobiva veliku količinu knjiga dok iz skladišta knjige izlaze u manjim pakiranjima po korisniku. S povećanjem broja skladišta smanjuje se iznos izlaznih troškova ali se s druge strane povećava broj skladišta i samim time i iznos troškova po lokaciji.

Svaka individualna distribucijska mreža iziskuje različite logističke troškove koji se tiču zaliha, transporta, skladišta i manipulacija kao i informacijskih sustava. Tvrtka mora imati barem toliki broj skladišta koji će smanjiti logističke troškove i smanjiti vrijeme odgovora na narudžbu. Amazon zato nema jedno nego 6 skladišta, s ciljem smanjenja troškova prijevoza i sa istovremenim smanjenjem vremena odgovora na narudžbu korisnika. Istovremeno dok se troškovi prijevoza smanjuju s povećanjem broja skladišta, rastu troškovi skladištenja i držanja zaliha. Kako broj skladišta raste, zbog gore navedenih razloga, ukupni logistički troškovi najprije padaju ali zatim rastu kako je prikazano na slici 4. Tvrtka bi trebala povećavati broj skladišta ili prodajnih lokacija samo ako su analize pokazale da će budući profit to nadoknaditi.



Slika 4. Odnos logističkih troškova u odnosu na vrijeme odgovora i broj lokacija

Izvor: Prilagodio autor iz izvora [6]

2.2.2. Vrste dizajna distribucijske mreže unutar opskrbnog lanca

Prilikom kreiranja distribucijske mreže mnogi parametri moraju biti uzeti u obzir, ali je ključno za logističare da odgovore na dva pitanja: [3]

1. Hoće li proizvod biti dostavljen na lokaciju korisnika ili će biti pokupljeni na predodređenoj lokaciji?
2. Hoće li za distribuciju proizvoda biti korišten posrednik (ili posredna lokacija)?

Prema odgovorima na ova pitanja i vrsti industrije kojom se tvrtka bavi, bit će izabrana jedna od 6 verzija distribucijske mreže za kretanje proizvoda od tvornice do korisnika: [3]

1. Proizvodno skladište sa direktnom dostavom
2. Proizvodno skladište sa direktnom dostavom i spajanjem proizvoda u tranzitu
3. Distribucijsko skladište sa isporukom pošiljaka pomoću posrednika
4. Distribucijsko skladište sa isporukom pošiljaka direktno korisniku
5. Proizvodno/distribucijsko skladište sa preuzimanjem pošiljaka od strane korisnika
6. Trgovinsko skladište sa preuzimanjem pošiljaka od strane korisnika

2.2.2.1.Proizvodno skladište s direktnom dostavom

Koristeći ovaj način distribucijske mreže, proizvod ili usluga se isporučuje direktno od proizvođača do krajnjeg korisnika, pritom zaobilazeći trgovca. Trgovac u ovom slučaju ima zadatak da preuzme narudžbe od kupca i inicira zahtjev za dostavu, a njegova velika prednost ovdje je ta da nema nikakvih zaliha a samim time ni troškova držanja ili manipuliranja istim. Najveća prednost ovakvog sustava je upravo ta mogućnost centralizacije zaliha kod proizvođača. Agregirajući potražnju skupljenu kod svih trgovaca, proizvođač ostvaruje manje troškove jer sve zalihe drži na jednom mjestu. Također, ovaj način nudi proizvođaču mogućnost odlaganja prilagodbe proizvoda sve do trenutka dok korisnik ne plasira narudžbu što bi dodatno smanjilo razinu i troškove zaliha. Osim toga, radi postojanja samo proizvodnog i/ili distribucijskog skladišta proizvođača smanjeni su ukupni troškovi za postrojenja. Također, troškovi manipuliranja robom značajno se mogu smanjiti ako proizvođač može organizirati slanje pošiljaka direktno sa proizvodne linije. Ovakav način distribucije može ponuditi visoku dostupnost i varijabilnost proizvoda zbog spajanja zaliha proizvoda kod proizvođača, kao i brz pristup proizvoda na tržište.

S druge strane, troškovi transporta u ovom slučaju su veći radi povećane udaljenosti i odvojenog slanja za svakog posebnog korisnika. Isti proizvođač tenisica u ovom slučaju sam će snositi troškove dostave tenisica do svakog krajnjeg korisnika pojedinačno umjesto uobičajenog zbirnog slanja robe prema trgovcu. Troškovi također rastu zbog značajnih ulaganja u informacijsku infrastrukturu radi integracije proizvođača i trgovaca kao i u slučaju povrata robe. Nezadovoljstvo ovakvih načinom može biti i zbog dužih vremena isporuke od jednog do dva tjedna zbog povećane udaljenosti i dvije razine naručivanja (kupac-trgovac pa trgovac-proizvođač).

Uzimajući u obzir sve date parametre, ovakav sustav distribucije poželjno je koristiti za

različite proizvode s manjom potražnjom a velikom vrijednosti, na koje su korisnici spremni čekati i prihvatiti više pojedinih pošiljaka od različitih proizvođača (ponekad narudžba sadrži više proizvoda od više proizvođača). Primjerice, pojedini proizvođač tenisica može se odlučiti na ovaj način ako u svom asortimanu ima tenisice koje su limitirana kolekcija i imaju veliku vrijednost radije nego za sve tenisice u asortimanu. [3]

2.2.2.2.Proizvodno skladište s direktnom dostavom i spajanjem proizvoda u tranzitu

Ovaj način distribucije veoma je sličan prethodnom s osnovnom razlikom: za razliku od čiste direktne dostave u kojoj se proizvod šalje direktno od proizvođača do kupca, ovaj način kombinira sve dijelove narudžbe sa različitih lokacija tako da kupac dobije samo jednu dostavu. Ovo u principu predstavlja veliku prednost u odnosu na prvu distribucijsku mrežu. Primjerice ako korisnik naruči računalo tvrtke Samsung zajedno s tipkovnicom tvrtke Siemens, posrednik će pokupiti ta dva proizvoda, konsolidirati ih u jednu narudžbu i ispostaviti korisniku. Troškovi zaliha, dostupnost i varijabilnost proizvoda, vrijeme prema tržištu, način povrata su veoma slični kao kod obične direktne dostave. S druge strane, troškovi transporta su nešto manji (zbog konsolidacije robe prema korisniku) ali je investiranje u informacijski sustav nešto veće jer je sad potrebno uključiti u integraciju i posrednika. Sam doživljaj korisnika prema ovom načinu je bolji jer korisnik dobiva samo jednu dostavu u odnosu na mogućnost više dostava u prethodnom slučaju ali i zbog vidljivosti narudžbe koja se u ovom slučaju jedinstveno prati u odnosu na slučaj prije. [3]

2.2.2.3.Distribucijsko skladište sa isporukom pošiljaka pomoću posrednika

Koristeći se ovom vrstom distribucijske mreže, zalihe se ne drže kod proizvođača nego kod distributera/trgovca u skladištu a dostavljači se koriste za transport proizvoda do krajnjih korisnika.

Zbog veće ovisnosti o kretanjima u potražnji, distributer mora držati veće količine zaliha nego proizvođač u prethodna dva slučaja te ovakvi načini distribucije su prikladnije za proizvode s većom potražnjom i većim koeficijentom obrtaja, dok su za proizvode s manjim koeficijentom prikladniji načini distribucije direktno od proizvođača. Troškovi postrojenja su nešto veći nego u direktnoj ispostavi, a razlika se povećava kada je riječ o slabo obrtajnim artiklima. Isti slučaj je i sa vremenom potrebnim da proizvod dođe do tržišta: nešto je duže radi još jednog sudionika u lancu. Iako su asortiman proizvoda koji se nalazi na skladištu i njihova dostupnost nešto manji nego kod proizvođača, ovakav način distribucije pruža slijedeće prednosti: manje troškove

transporta zbog mogućnosti zbirnog transporta (posebno kod visoko obrtajnih artikala), jednostavniju informatičku infrastrukturu, brže vrijeme odgovora na zahtjeve korisnika, lakšeg manipuliranja povratom, bolje vidljivosti pošiljaka i u konačnici većeg korisničkog zadovoljstva radi brže isporuke. [3]

2.2.2.4.Distribucijsko skladište sa isporukom pošiljaka direktno korisniku

Isporuka pošiljaka direktno korisniku iz distribucijskog skladišta generira najviše transportne troškove u odnosu na ostale distribucije iz veoma jednostavnog razloga: koristeći dostavljača kao u prethodnom slučaju, dolazi do konsolidacije proizvoda pa dolazi do uporabe ekonomije obujma koju dostavljači lakše postignu na temelju većeg broja trgovaca ili distributera. U nekim slučajevima postoje iznimke: osobna dostava velikih i težih proizvoda pokazala se dobrom u ovom slučaju jer je za njih korisnik spreman platiti dostavu (npr. u Kini se za dostavu velikih bačvi vode i vreća riže ovaj pristup pokazao veoma uspješnim).

Ovaj način distribucije također zahtjeva veći broj postrojenja/ skladišta što generira veće troškove i veće zalihe u odnosu na direktnu dostavu od proizvođača ali i nešto manje troškove i zalihe u odnosu na trgovinska skladišta. Prikladan je za brzo obrtajne artikle kao primjerice za najkorištenije proizvode robe široke potrošnje (npr. deterdžent). Dostupnost i varijabilnost proizvoda je manja nego kod direktne ispostave ali veća nego kod distribucije putem trgovinskih skladišta. U smislu vremena odgovora na korisnikov zahtjev, praćenja pošiljke i načina povrata, ovaj sustav nudi bolje uvjete nego prethodni i veoma sličan informatički sustav kao i sustav distribucije iz skladišta distributera preko dostavljača.

Ovaj slučaj se pokazao isplativijim onda kada su narudžbe korisnika toliko velike da one same mogu opravdati troškove dostave te tako mnogi trgovci danas nude besplatnu dostavu nakon određene razine narudžbe. [3]

2.2.2.5.Proizvodno/distribucijsko skladište sa preuzimanjem pošiljaka od strane korisnika

U ovom pristupu organizaciji distribucijske mreže, zalihe su skladištene ili na skladištu proizvođača ili distributera dok su narudžbe korisnika plasirane online putem te ih korisnik sam mora pokupiti na dogovorenom mjestu preuzimanja. Potrebna su značajna ulaganja u informatičku infrastrukturu te je veoma važna vidljivost pošiljke u svakom trenutku. Troškovi zaliha mogu se držati manjima jer ili proizvođač ili distributer mogu spojiti veće količine zaliha na jednom od svojih skladišta. Pojedine tvrtke drže zalihe brzo obrtajnih proizvoda na mjestima

preuzimanja, dok se sporo obrtajni proizvodi drže na centralnom skladištu ili kod proizvođača. Zbog konsolidacije proizvoda troškovi transporta su manji u odnosu na korištenje dostavljača. Najbolji primjer je taj da tvrtke ukoliko koriste vlastiti dućan kao lokaciju preuzimanja, imaju veoma male troškove jer istu robu naručenu online putem voze skupa sa robom koja ide za prodaju u dućanu. Ukoliko se koriste već postojeća skladišta ili dućani kao mjesta preuzimanja, troškovi postrojenja su također mali. Dostupnost i varijabilnost proizvoda je veoma slična kao i kod proizvodnog i distribucijskog skladišta, dok je način povrata lakši zbog toga jer se na lokacijama prikupljanja može obaviti i povrat. [3]

2.2.2.6.Trgovinsko skladište sa preuzimanjem pošiljaka od strane korisnika

Glavne prednosti ovog sustava, koji se s pravom može zvati tradicionalnim sustavom, ogledaju se u niskim troškovima dostave i najbržim odgovorom na zahtjeve korisnika u odnosu na ostale sustave. Međutim s druge strane, povećava se razine zalihe i troškovi postrojenja jer se tu radi o velikom broju dućana te su ovakvi sustavi najbolji za brzo obrtajne proizvode za koje će korisnici cijeniti brzi odgovor. Potrebna je minimalna informatička infrastruktura jer ovdje korisnici jednostavno ušeću u dućan i kupe proizvod (osim u slučaju online narudžbi). Dostupnost i varijabilnost proizvoda je manja nego u ostalim slučajevima.

Primjera za ovaj slučaj nalazimo bilo gdje, počevši od dućana za odjeću, svakodnevne namirnice odnosno za gotovo svaki proizvod koji se nalazi u komercijalnoj prodaji. [3]

S napretkom tehnologije i razvojem globalizacije, postalo je jasno kako suvremene tvrtke ne mogu koristiti samo jedan od navedenih načina nego moraju kombinirati više njih istovremeno. Primjerice, danas je teško pronaći tvrtku koja ne nudi više od jednog načina naručivanja, isporuke i sl. Postoje razne mogućnosti online naručivanja i preuzimanja u dućanu ali i na drugim definiranim mjestima. Također, danas su distribucijska skladišta prerasla svoju prvenstvenu ulogu koja je podrazumijevala samo skladištenje pa danas postoje logističko-distributivni centre u kojima firme skladište ali i same organiziraju transport pošiljaka na najefikasniji mogući način.

2.3. Primjer suvremenog opskrbnog lanca u modnoj industriji

Skraćivanje roka trajanja proizvoda ali i sve veća potražnja sa što bržim vremenom odgovora najviše se ističu u modnoj industriji. Odjeća je odavno prestala biti samo sredstvo za zaštitu od hladnoće nego je danas i odraz životnog stila osobe koja je nosi. Iz toga razloga, moralo je doći do razvoja izuzetno prilagodljivih i okretnih opskrbnih lanaca koji su u stanju na izuzetno nestabilnu potražnju u modnoj industriji reagirati brzo i točno onako kako potražnja zahtijeva ali i prepoznati poslovnu priliku prije svojih konkurenata. U narednom djelu, na temelju realnog primjera, prikazat će se opskrbni lanac jedne od najvećih tvrtki u modnoj industriji: Inditex-a, pritom posebno obraćajući pažnju na njihovu najpopularniju tvrtku kćer: Zara.[7]

Zara predstavlja modnu marku sa lancem modnih dućana osnovanih 1975. godine u sklopu grupacije Inditex. Tijekom protekla 3 stoljeća, Zara je utrostručila svoj profit ali i broj dućana. Na godišnjoj bazi više od 3000 dizajnera lociranih u središtu tvrtke u Španjolskoj dizajnira preko 40 000 komada odjeće od kojih samo 10 000 ide u proizvodnju. Za razliku od svojih konkurenata, Zara 50 posto svoje proizvodnje i dalje drži u Europi a ne u Aziji ili Južnoj Americi. [8]

Stručnjaci koji su proučavali opskrbni lanac Zare dijele ga u 5 dijelova:[9]

1. Organizacija i dizajn proizvoda:

U planiranju proizvoda Zara koristi taktiku koja je izdvaja od drugih. Prateći vodeće trendove u korak te pritom kopirajući vrhunske i skuplje marke, u mogućnosti su dizajnirati kolekciju bez agencija koje bi im predviđale potražnju mjesecima ili godinu dana unaprijed. No posebna stvar su tkanine koje se rabe. One se moraju naručiti dosta prije zbog dugih vremena nabave ali i jer moraju biti prisutne prije početka sezone. Problem s predviđanjem te potražnje uspjeli su kontrolirati naručivanjem materijala u bijeloj boji što im daje mogućnost promjene boje naknadno prema vodećim trendovima trenutno. Svoje aktivnosti poput dizajna, prototipa i kompjuterskog šivanja tkanina obavljaju u vlastitoj režiji, dok samo šivanje i farbanje tkanina prepuštaju vanjskom davatelju usluga koji se nalazi blizu njihovog središta.

2. Nabava

Za svaku tvrtku nabava je bitna iz mnogo razloga. S razvojem globalnih tržišta i sve okretnijim opskrbnim lancima, moguće je ponuditi sve više različitih materijala po veoma različitim cijenama. To direktno utječe na finalni proizvod, čineći konkurentnijim, moguće jeftinijim i samim time dostupnijim korisnicima. Sve je više proizvoda na tržištu sa sve kraćim životnim ciklusom. Zara je taj problem riješila sa proizvodnjom malih količina ali raznovrsnijim asortimanom. Na taj način, roba se šalje u dućane svaki tjedan te se smanjuju troškovi promocije

i zaliha.

3. Proizvodnja

Dvije glavne prepreke u planiranju potražnje a samim time i proizvodnje su njena kompleksnost i nepredvidljivost. Zara je taj problem u proizvodnji riješila na ovaj način: imaju dvije linije proizvodnje, jedna sa komadima odjeće koji su nosivi stalno bez vremenskog trajanja na polici dućana a koji se proizvode uglavnom u Kini, te druga linija koja je limitirana i koja ima komade odjeće koji su u tom trenutku moderni a koji se uglavnom proizvode u Španjolskoj i Portugalu. Prvi, zbog lokacije i obujma proizvodnje imaju manje troškove proizvodnje i duže vrijeme nabave u odnosu na druge. Ono što bliža proizvodnja nudi je jako brz odgovor na potražnju, a u slučaju da se ta manja kolekcija ne proda dobro, može se brzo povući sa tržišta i zamijeniti novom.

4. Distribucija proizvoda

Kao što je navedeno i prije, Zara isporuku u svoje dućane obavlja dva puta tjedno. Za usporedbu, za odjeću s bliskog istoka vrijeme nadopunjavanja dućana je 6 do 9 mjeseci ili 4 mjeseca za neki internacionalnu modnu marku. Distribucija se obavlja iz velikog distribucijskog centra u Španjolskoj, veličine preko 400 000 kvadratnih metara i više manjih centara u Argentini, Brazilu i Meksiku.[10]

Vrijeme isporuke ili nedostatak proizvoda na polici bitno utječe na sliku tvrtke. Zahvaljujući brzoj reakciji na potražnju, Zara svoje dućane održava svježim te kupci svaki tjedan imaju priliku kupiti neku novu stvar.

5. Prodaja i reakcija korisnika

Prodajni stručnjaci u Zari istraživanje provode kroz skupljanje i obradu još neobrađenih podataka te testiranje pretpostavki. Sve počinje od dućana u kojima menadžeri dućana sami sastavljaju narudžbe na temelju prodaje u određenom vremenskom roku te se ti podaci šalju u središte tvrtke u kojem stručnjaci zajedno sa tržišnim specijalistima ali i kupcima analiziraju podatke te prave buduće planove.

Zara svoj svjetski uspjeh može zahvaliti bliskoj komunikaciji sa svojim kupcima, stalnom radu na odnosu s njima te mogućnosti plasiranja robe u dućane na vrhuncu potražnje u tjednu. Spretan i okretan opskrbni lanac može zahvaliti velikom timu stručnjaka od dizajnera, prodajnih stručnjaka i menadžera na jednom mjestu i proizvodnji blizu njih. Zahvaljujući osobnom vlasništvu svojih dućana i nekorištenju franšiza, omogućena je precizna organizacija svih procesa. Zaključak bi bio kako je cijela tvrtka zapravo spremna brzo reagirati na bilo koju promjenu pa je takav i opskrbni lanac unutar nje.

3. MOGUĆNOSTI OPTIMIZACIJE DISTRIBUCIJSKE MREŽE PRIMJENOM MATEMATIČKIH MODELA

Matematički modeli i metode optimiranja u prometnom sustavu predstavljaju primjenu kvalitativnih metoda za rješavanje kompleksnih problema u sustavu od ljudi, prometnica, tereta, prometnih objekata, informacija i kapitala. Zadatak tih metoda je u tome da donositeljima odluke osiguraju da politiku i mjere za realizaciju odluke postave na znanstvenim osnovama i da ih, po mogućnosti, temelje na mjerljivim veličinama. Polazna osnovica za takav pristup je stvarnost, gdje nastaju problemi, a postojeća problematika mora se ograničiti i svesti na najbitnije čimbenike koji je obilježavaju, što znači da matematički modeli sadrže određen stupanj apstrakcije. [11]

Matematički modeli čine samo jedan dio u cjelokupnom operacijskom istraživanju, nebitno bilo to u polju distribucije ili nečeg drugog. Sve faze kroz koje istraživanje mora proći su:

1. Definiranje problema od interesa i sakupljanje relevantnih podataka
2. Formuliranje matematičkog modela za prikazivanje problema
3. Razvijanje modela na kompjuterskom sučelju za razvoj rješenja
4. Testiranje modela i izmjene ako je potrebno.
5. Priprema za aplikaciju modela u stvarni svijet
6. Implementacija [12]

3.1. Izrada modela

U razvoju modela je najbolje započeti sa veoma jednostavnim primjerom pa se onda prebaciti na naprednije modele koji bolje prikazuju kompleksnost problema.

O razvoju početnog matematičkog modela ovisi i razvoj samog sustava na kraju. Nakon što je definiran problem, slijedeća faza je preformulacija tog problema u formu koja je najbolja za analizu, u ovom slučaju matematičku formu.

Matematički model poslovnog problema je sustav jednadžbi i s njima povezanih matematičkih izraza koji opisuju problem. Stoga, ako postoji n različitih kvantitativnih odluka koje se trebaju donijeti, one se predstavljaju kao varijable odluke (npr. $x_1, x_2 \ldots, x_n$) koje predstavljaju vrijednosti koje moraju biti određene.

Odgovarajuća mjera izvedbe (npr. profit) je izražena kao matematička funkcija varijabli odluke (npr. $P = x_1 + 3x_2 + \ldots + 5x_n$). Ova funkcija se naziva funkcija cilja.

Sva ograničenja na vrijednostima koje mogu biti dodijeljene varijablama odluke također

su izražena matematički, obično preko nejednakosti jednadžbe (npr. $x_1+3x_2+\ldots.+5x_n \geq 10$). Ovakvo matematičko izražavanje se naziva ograničenje.

Na lijevoj strani zadanih ograničenja i često funkcije cilja nalaze se konstante koje se nazivaju parametrima modela (uglavnom, koeficijenti zadani iz realnog okruženja problema). Tako se za matematički model može reći kako je nužno pronaći odgovarajuće vrijednosti varijabli odlučivanja na taj način da se maksimizira/minimizira funkcija cilja, a unutar svih ograničenja. [12]

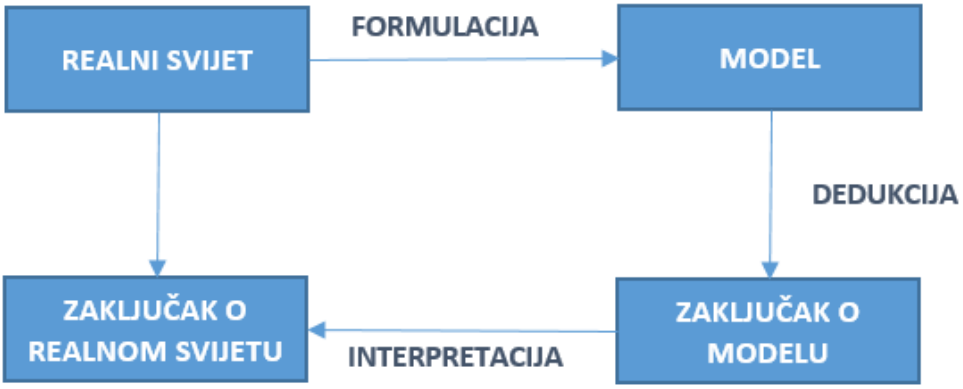
Prilikom matematičkog modeliranja nužno se držati određenih principa koji su navedeni u nastavku: [11]

1. Ne izrađivati kompliciran model ako i jednostavan može poslužiti. Preporučljiv je postupak pojednostavljenja sve dok rješenje ne postane matematički izvodljivo, a nakon toga slijedi obogaćivanje modela.
2. Ne podešavati problem kako bi odgovarao tehnici rješenja. Kod snimanja stanja u realnom problemu treba paziti na to da se podsvjesno ne iskrivi slika u nastojanju da se problem svede u oblik koji se može riješiti nekom od poznatih nam tehnika.
3. Postupak stvaranja zaključaka o modelu mora biti rigorozan. Logičke pogreške u obradi modela ne smiju promaknuti jer može doći do situacije u kojoj dolazi do greške u programskoj obradi iako je potpuno ispravna ali je ugrađena logička pogreška na početku.
4. Model treba provjeriti prije ugradbe. Može se testirati na stvarnim, već ugrađenim podacima, ili ako takvih nema, generirati ulazne i na taj način provjeriti ispravnost reakcije modela.
5. Model ne treba nikada shvaćati previše doslovno. Rezultati koji se dobiju obradom modela moraju se usporediti s iskustvenim podacima da se uoči jesu li logični.
6. Ne treba očekivati da model rješava probleme za koje nije bio projektiran. Rješenje modela je postavljeni cilj na početku te se izmjenom cilja ne postiže adekvatni model.
7. Ne treba pretjerati s „prodavanjem“ istog modela. Jednom izgrađen model uz određene izmjene može poslužiti i za rješavanje različitih vrsta problema, ali se treba voditi računa o promjenama.
8. Znatne su koristi već od izrade modela. Izradom modela mogu se utvrditi neke činjenice koje u stvarnosti pobjegnu istraživaču. Primjerice, prilikom izradbe modela proizvodnje, može se otkriti kako postoje proizvodi čija je prodajna cijena niža od izravnih troškova izvedbe.
9. Model ne može biti bolji od ulaznih informacija. Kvaliteta ulaznih informacija ne

može biti gora od kvalitete modela pa se napori trebaju usmjeriti prema poboljšanju kvalitete podataka.

10. Modeli ne mogu nadomjestiti donositelja odluke. Njima se donosi samo podloga na temelju koje donositelj odluke donosi samu odluku.

Grafički prikaz izrade modela prikazan je na slici 2.



Slika 5. Proces modeliranja

Izvor: Prilagodio autor iz izvora [11]

3.2. Modeli za optimizaciju distribucijske mreže

Cilj svakog menadžera prilikom lociranja postrojenja i dodjele odgovarajućeg kapaciteta svakom od njih je maksimiziranje profita odnosno smanjenje troškova opskrbnog lanca, pritom zadržavajući efikasnost i zadovoljstvo korisnika. Profit dolazi od prodaje proizvoda dok troškovi nastaju od postrojenja, rada, transporta, materijala i zaliha. Osim toga, profiti su podložni promjenama nakon poreza i tarifa, iako bi u idealnom slučaju profit trebao biti maksimiziran nakon njih.

Prilikom odluke o dizajnu mreže nužno je imati slijedeće podatke: [3]

- Lokaciju izvora opskrbe i tržišta
- Lokaciju potencijalnih lokacija postrojenja
- Prognozu potražnje po tržištima
- Troškove postrojenja, rada i materijala po lokaciji
- Troškove transporta između svake od lokacija
- Troškove zaliha po lokaciji
- Prodajnu cijenu proizvoda u različitim regijama

- Tarife i poreze
- Željeno vrijeme odgovora i druge čimbenike usluge

Odluke o dizajnu distribucijske mreže donose se u četiri faze: Definicija strategije opskrbnog lanca, definicija konfiguracije regionalnih postrojenja, izbor seta željenih potencijalnih lokacija gdje će postrojenja biti smještena i izbor točne lokacije za svako pojedino postrojenje. [3]

Prema tome u kojoj se, gore navedenoj fazi koriste, razlikujemo različite modele za optimizaciju distribucijske mreže.

3.2.1. Modeli optimizacije u drugoj fazi

Tijekom druge faze, menadžer uzima u obzir regionalnu potražnju, tarife, ekonomiju obujma i objedinjuje sve čimbenike troška za odluku regije u kojoj će postrojenja biti locirana.

Prilikom izrade ovakvih modela, menadžeri moraju imati u vidu mnogo kriterija. Jasno kako će veći broj postrojenja smanjiti transportne troškove i vrijeme isporuke kupcu, ali će također i povećati troškove fiksne troškove postrojenja i zaliha.

Modeli se koriste kada menadžer želi odrediti potreban broj lokacija za opskrbu tržišta kao i kapacitete koje će pridružiti svakoj lokaciji, i nakon toga za dodjelu trenutne potražnje svakoj od dostupnih lokacija. Ono što je bitno je da se te odluke donose za duži vremenski period i da ne mogu promijeniti tako lako. Postoje dva, veoma slična modela za optimizaciju mreže a jedina njihova razlika sa stajališta kapaciteta: model lokacije postrojenja sa određenim kapacitetom i bez određenog kapaciteta.

3.2.1.1. Model s određenim kapacitetom postrojenja

U modelu s određenim kapacitetom koriste se slijedeći ulazni parametri:[13]

- J = broj potencijalnih lokacija korisnika (npr. korisnička područja, dućani, točke potražnje), J={1,…,n}
- d_j = Potražnja korisnika j za svaki proizvod
- I = set potencijalnih lokacija za nova postrojenja, I = {1,…,m}
- Q = kapacitet novog postrojenja uspostavljenog na potencijalnog lokaciji i
- f_i = fiksni troškovi uspostavljanja i rada novog postrojenja na lokaciji (gradnja/iznajmljivanje, rad, osoblje, osiguranje…) i, i € I
- t_{ij} = troškovi distribucije jedinice jednog proizvoda od potencijalne lokacije i do korisnika j (proizvodnja, skladištenje, troškovi rukovanja, tarife), i € I, j € J

Model se fokusira na minimiziranje troškova, a za pojednostavljenje utjecaj tarifa i poreza je izostavljen. [13]

Varijable odlučivanja:

X_{ij} = količina poslana od nove lokacije i do korisničke lokacije j (3.2.1.1.1.)

$$i = 1, \dots, m$$

$$j = 1,\dots,n$$

$$y_i = \begin{cases} 1 \text{ Ako je lokacija uspostavljena na potencijalnoj lokaciji i} \\ \\ 0 \text{ Inače} \end{cases} \qquad i= 1,\dots,m \qquad (3.2.1.1.2.)$$

Funkcija cilja minimizira totalne troškove (fiksne troškove lokacije + varijabilne transportne troškove):

$$\text{Min } z = \sum_{i=1}^{m} f_i * y_i + \sum_{i=1}^{m} \sum_{j=1}^{n} t_{ij} * x_{ij} \qquad (3.2.1.1.3.)$$

Ograničenja:

Ograničenje kapaciteta:	$\sum_{j=1}^{n} x_{ij} \leq Q_i * y_i$	i= 1,…, m	(3.2.1.1.4.)
Ograničenje potražnje:	$\sum_{i=1}^{m} x_{ij} = d_j$	j= 1,…, n	(3.2.1.1.5.)
Ograničenje ne-negativnosti:	$x_{ij} \geq 0$	i=1,…,m ; j=1,…,n	(3.2.1.1.6.)
Ograničenje binarnih varijabli	$y_i \in \{0,1$	i=1,…, m	(3.2.1.1.7.)

3.2.1.2. Model s neodređenim kapacitetom postrojenja

U ovom modelu, ograničenje kapaciteta nije povezano sa potencijalnom lokacijom postrojenja. To je slučaj kada su, u dizajniranju opskrbnog lanca, kapaciteti potpuno fleksibilni i mogu biti određeni tek kada su lokacije naknadno odabrane.

Svi isti ulazni parametri za model s određenim kapacitetom se koriste i za ovaj model.

Model određenog kapaciteta se vrlo lako može adaptirati u model s neodređenim kapacitetom na različite načine, a najlakši način je da se kapacitet na svakoj lokaciji postavi na sumu cjelokupne potražnje:[13]

$$Q_i = \sum_{j=1}^{n} dj \qquad i \in I \qquad (3.2.1.2.1.)$$

Generalno obilježje ovog modela je to da optimalno rješenje postoji samo u slučaju kada je potražnja svakog korisnika zadovoljena iz samo jednog postrojenja.

Dolazi do redefiniranja varijabli odlučivanja: varijabla y_i ostaje ista ali se varijabla x_{ij} mijenja:

$$x_{ij} = \begin{cases} 1 \text{ Ako je korisnik j dodijeljen postrojenju uspostavljenom na lokaciji i} \\ 0 \text{ Inače} \end{cases} \quad i= 1,\ldots,m \ ,j= 1,\ldots m \qquad (3.2.1.2.2.)$$

Funkcija cilja minimizira totalne troškove (fiksne troškove lokacije + varijabilne transportne troškove):

$$\text{Min } z = \sum_{i=1}^{m} f_i * y_i + \sum_{i=1}^{m} \sum_{j=1}^{n} d_j * t_{ij} * x_{ij} \qquad (3.2.1.2.3.)$$

Ograničenja:

Zadovoljenje potražnje: $\sum_{j=1}^{n} x_{ij} = 1$ $i=1,\ldots,m$ $j= 1,\ldots, n$ (3.2.1.2.4.)

Ograničenje binarnih varijabli: $x_{ij} \leq y_i$ ili $x_{ij} \leq 0$ $j= 1,\ldots, n$ $i=1,\ldots,.m$ (3.2.1.2.5.)

Ograničenje ne-negativnosti: $x_{ij} \geq 0$ $i=1,\ldots,m$; $j=1,\ldots,n$ (3.2.1.2.6.)

Ograničenje binarnih varijabli: $y_i \in \{0,1\}$ $i=1,\ldots, m$ (3.2.1.1.7.)

3.2.2. Modeli optimizacije u trećoj fazi

Tijekom treće faze, menadžer mora identificirati potencijalne geografske lokacije u svakog regiji na kojima bi tvrtka mogla locirati tvornicu. Lokacija mora minimizirati trošak transporta sirovina od dobavljača do tvornice i gotovih proizvoda na tržište.

Modeli koji se koriste u ovoj fazi nazivaju se gravitacijski modeli i promatraju i tržišta i izvore opskrbe kao mrežne točke te podrazumijevaju da transportni troškovi rastu linearno sa poslanom količinom.

U narednom matematičkom modelu određuje se lokacija jednog postrojenja koje dobiva sirovine od dobavljača i šalje gotove proizvode na tržište.

Koriste se slijedeći ulazni parametri: [3]

- (x_n,y_n) = koordinate lokacije ili tržišta ili izvora opskrbe n

- F_n = trošak slanja jedne jedinice po kilometru između postrojenja i tržišta ili izvora opskrbe n
- D_n = količina poslana između postrojenja i tržišta ili izvora opskrbe n

Ako je (x, y) lokacija određena za postrojenje, udaljenost d_n između postrojenja na lokaciji (x, y) i izvora opskrbe ili tržišta je dana formulom: [3]

$$d_n = \sqrt{(x - x_n)^2 + (y - y_n)^2} \qquad (3.2.2.1.)$$

Ukupni troškovi transporta računaju se po slijedećoj formuli: [3]

$$TC = \sum_{n=1}^{k} d_n * D_n * F_n \qquad (3.2.2.2.)$$

Gravitacijski modeli također se mogu riješiti ponavljajući slijedeći postupak: [3]

1. Za svaki izvor opskrbe ili tržište n, odrediti d_n kako je definirano u formuli 3.2.2.1.
2. Odrediti novu lokaciju (x',y') za postrojenje, gdje je

$$x' = \frac{\sum_{n=1}^{k} \frac{D_n * F_n * X_n}{d_n}}{\sum_{n=1}^{k} \frac{D_n * F_n}{d_n}} \text{ i } y' = \frac{\sum_{n=1}^{k} \frac{D_n * F_n * y_n}{d_n}}{\sum_{n=1}^{k} \frac{D_n * F_n}{d_n}} \qquad (3.2.2.3.)$$

3. Ako je nova lokacija (x',y') skoro ista kao (x, y) zaustaviti proces. Inače, ako je (x, y) = (x',y') ponovno se vratiti na korak 1.

3.2.3. Modeli optimizacije u četvrtoj fazi

Tijekom četvrte faze, menadžeri moraju odlučiti o lokaciji i kapacitetu za svako postrojenje i pored toga moraju donijeti odluka kako će tržišta biti dodijeljena postrojenjima. Pritom se mora voditi računa o razini usluge i vremenu odgovora na korisnički zahtjev. Sve te odluke se moraju donijeti zajedno tako da jedna ne poništava drugu.

3.2.3.1. Model dodjele potražnje proizvodnim postrojenjima

Svake godine na temelju istraživanja tržišta i povijesnih podataka, donose se odluke o dodjeli potražnje na proizvodna postrojenja sukladno promjeni potražnje i troškova.

U modelu se koriste slijedeći ulazni parametri: [3]

- n = broj lokacija tvornica
- m = broj tržišta ili točki potražnje
- D_j = godišnja potražnja tržišta j
- Q_i = kapacitet tvornice i
- c_{ij} = trošak proizvodnje i slanja jedne jedinice od tvornice i do tržišta j (troškovi uključuju proizvodnju, zalihe i transport)

Cilj je dodijeliti potražnju za različita tržišta različitim tvornicama kako bi se minimizirali troškovi postrojenja, transporta i zaliha.

Definirana je jedna varijabla odlučivanja: [3]

x_{ij} = količina poslana od tvornice i do tržišta j

Funkcija cilja je formulirana kao: [3]

$$\text{Min } Z = \sum_{i=1}^{n} \sum_{j=1}^{m} C_{ij} * x_{ij} \qquad (3.2.3.1.1.)$$

Koriste se slijedeća ograničenja: [3]

Zadovoljenje ograničenja potražnje $\sum_{i=1}^{n} x_{ij} = D_j \quad j = 1,\ldots,m$ (3.2.3.1.2.)

Zadovoljenje ograničenja kapaciteta $\sum_{j=1}^{m} x_{ij} \leq Q_i \quad i = 1,\ldots,n$ (3.2.3.1.3.)

3.2.3.2. Model lociranja tvornica i skladišta istovremeno

Prilikom dizajniranja cjelokupnog opskrbnog lanca, za razliku od prethodnog lokacijskog modela tvornica, potrebno je uzeti u obzir puno više čimbenika. Lokacije i dodjela kapaciteta moraju biti napravljene i za tvornice i za skladišta. Više skladišta može biti korišteno za zadovoljenje potražnje i mnoge tvornice mogu biti korištene za zamjenu skladišta. Uzima se pretpostavka da jedna ulazna jedinica iz izvora opskrbe proizvodi jednu izlaznu jedinicu gotovog proizvoda.

Za model su potrebni idući ulazni parametri: [3]

m = broj tržišta ili točki potražnje

n = broj potencijalnih lokacija tvornica

l = broj dobavljača

t = broj potencijalnih lokacija skladišta

D_j= godišnja potražnja od korisnika j

Q_i =potencijalni kapacitet tvornice na lokaciji i

S_h= kapacitet dobavljača h

W_e=potencijalni kapacitet skladišta na lokaciji e

F_i= fiksni troškovi lociranja tvornice na lokaciji i

f_e= fiksni troškovi lociranja skladišta na lokaciji e

c_{hi}= trošak slanja jedne jedinice od dobavljača h do tvornice i

c_{ie}= trošak proizvodnje i slanja jedne jedinice iz tvornice i do skladišta e

c_{ej}= trošak slanja jedne jedinice od skladišta e korisnika j

Cilj ovog modela je ustanoviti lokaciju tvornica i skladišta kao i količine koje se šalju između različitih točki kako bi se minimizirali totalni fiksni i varijabilni troškovi.

Definirane su slijedeće varijable odlučivanja: [3]

x_{ej} = količina poslana od skladišta e do tržišta j

x_{ie} = količina poslana od tvornice na lokaciji i do skladišta e

x_{hi} = količina poslana od dobavljača h do tvornice na lokaciji i

$$e = 1, \dots, t$$
$$j = 1,\dots,n$$
$$i = 1,\dots,m$$
$$h = 1,\dots,l \qquad (3.2.3.2.1.)$$

$$y_i = \begin{cases} 1 \text{ Ako je tvornica locirana na lokaciji i} \\ 0 \text{ Inače} \end{cases} \qquad i= 1,\dots,m \qquad (3.2.3.2.2.)$$

$$y_e = \begin{cases} 1 \text{ Ako je skladište locirano na lokaciji e} \\ 0 \text{ Inače} \end{cases} \qquad e= 1,\dots,t \qquad (3.2.3.2.3.)$$

Funkcija cilja je onda formulirana kao slijedeća formula: [3]

$$\text{Min } Z = \sum_{i=1}^{n} F_i * y_i + \sum_{e=1}^{t} f_e * y_e + \sum_{h=1}^{l} \sum_{i=1}^{n} c_{hi} * x_{hi} + \sum_{i=1}^{n} \sum_{e=1}^{t} c_{ie} * x_{ie} + \sum_{e=1}^{t} \sum_{j=1}^{m} e_{ej} + x_{ej} \qquad (3.2.3.2.4)$$

Ograničenja: [3]

Ograničenje koje određuje da ukupna količina poslana od dobavljača ne može premašiti njegov kapacitet:

$$\sum_{i=1}^{n} x_{hi} \leq S_h \qquad h = 1,\ldots,l \qquad (3.2.3.2.5.)$$

Ograničenje koje određuje da ukupna količina poslana iz tvornice ne može premašiti primljenu količinu sirovina:

$$\sum_{h=1}^{l} x_{hi} - \sum_{e=1}^{t} x_{ie} \geq 0 \qquad i = 1,\ldots,n \qquad (3.2.3.2.6.)$$

Ograničenje koje određuje da ukupna količina poslana od dobavljača ne može premašiti njegov kapacitet:

$$\sum_{e=1}^{t} x_{ie} \leq K_i * y_i \qquad i = 1,\ldots,n \qquad (3.2.3.2.7.)$$

Ograničenje koje određuje da ukupna količina poslana iz skladišta ne može premašiti primljenu količinu iz tvornice:

$$\sum_{i=1}^{n} x_{ie} - \sum_{j=1}^{m} x_{ej} \geq 0 \qquad e = 1,\ldots,t \qquad (3.2.3.2.8.)$$

Ograničenje koje određuje da ukupna količina u skladištu ne može premašiti njegov kapacitet:

$$\sum_{j=1}^{m} x_{ej} \leq W_e * y_e \qquad e = 1,\ldots,t \qquad (3.2.3.2.9.)$$

Ograničenje koje određuje da ukupna količina poslana na tržišta mora zadovoljiti potražnju:

$$\sum_{e=1}^{t} x_{ej} = D_j \qquad j = 1,\ldots,m \qquad (3.2.3.2.10.)$$

Ograničenje koje određuje da je svaka tvornica ili skladište ili otvoreno ili zatvoreno:

$$y_i, y_e \in \{0,1\},\ x_{ej}, x_{ie}, x_{hi} \geq 0 \qquad (3.2.3.2.11.)$$

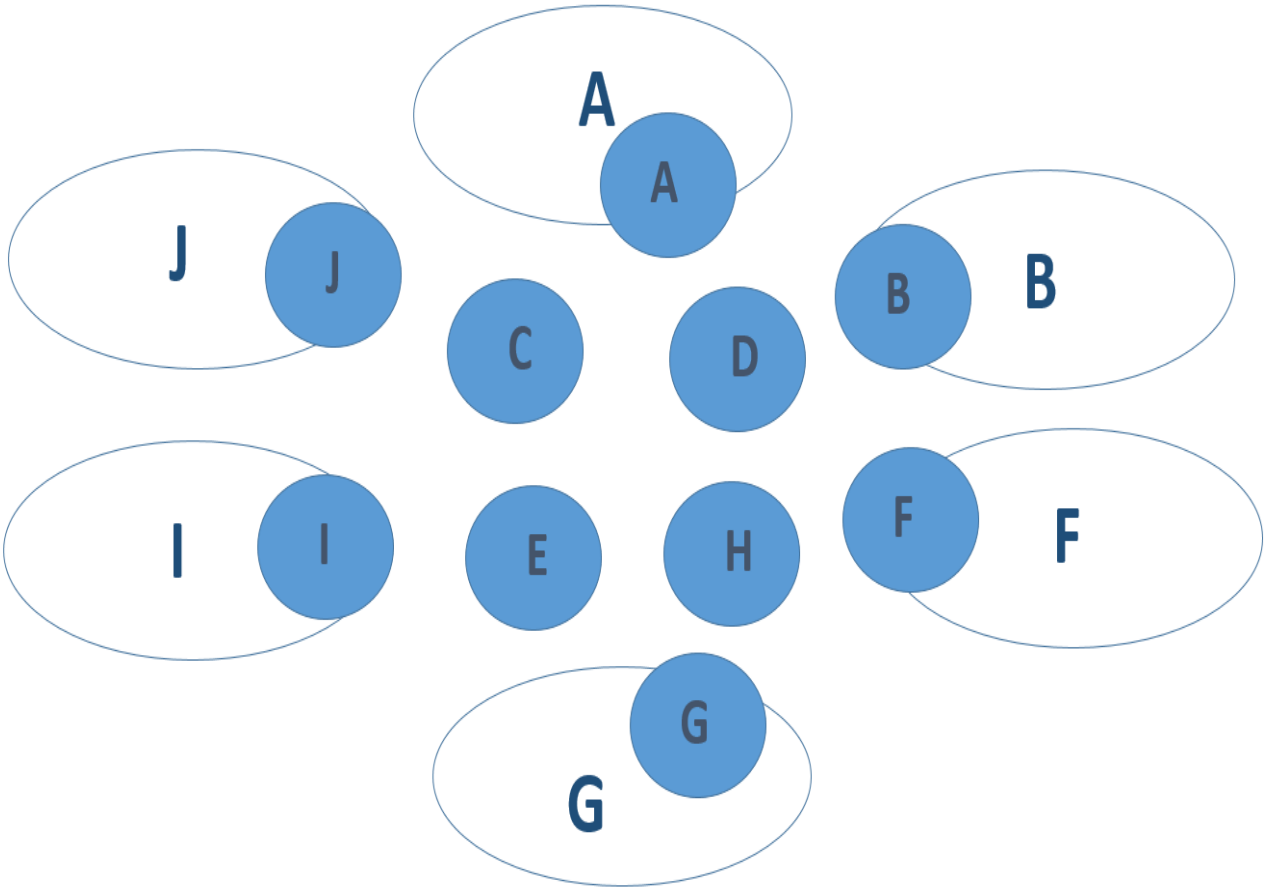
4. ANALIZA POSTOJEĆEG DISTRIBUCIJSKOG SUSTAVA U TVRTKI

MTH Beverage Company je njemačka tvrtka specijalizirana za proizvodnju bezalkoholnih proizvoda te njihovo pakiranje u boce. Radi plasiranja dva nova proizvoda koja su postala veoma popularna među mlađom populacijom na tržište, tvrtka je u zadnje vrijeme ostvarila neočekivani porast prodaje. Menadžment tvrtke sada sagledava mogućnosti reorganizacije distribucijske mreže tvrtke kako bi ponudili poboljšanu uslugu na 6 tržišta na kojima distribuiraju svoje proizvode.

U tu svrhu, identificirano je 10 potencijalnih lokacija gdje postoji mogućnost iznajmljivanja skladišnog prostora. U tablici 1. prikazane su udaljenosti (u kilometrima) između potencijalnih lokacija skladišta i regionalnih tržišta. Radi zaštite povjerljivih poslovnih informacija, imena potencijalnih lokacija i korisničkih tržišta bit će označena sa A, B, itd.

Tablica 1. Udaljenost (u km) između potencijalnih lokacija skladišta i regionalnih tržišta

Potencijalne lokacije skladišta	Regionalna tržišta					
	A	B	F	G	I	J
A	5,0	76,1	30,4	139,4	72,6	11,7
B	76,1	5,0	71,0	77,2	144,5	83,7
C	20,8	92,9	47,2	156,1	47,5	11,7
D	54,7	113,3	52,9	187,2	93,0	45,2
E	13,5	85,5	28,0	148,7	67,3	9,3
F	30,4	71,0	5,0	138,2	94,5	38,1
G	139,4	77,2	138,2	5,0	207,9	146,9
H	47,8	106,5	46,2	180,2	86,7	38,9
I	72,6	144,5	94,5	207,9	5,0	63,4
J	11,7	83,7	38,1	146,9	63,4	5,0



Slika 6. Potencijalne lokacije skladišta i regionalna tržišta

Izvor: Izradio autor

Na slici 6. prikazan je okvirni raspored potencijalnih lokacija skladišta u odnosu na regionalna tržišta. Može se primijetiti kako su pojedine potencijalne lokacije skladišta smještene u istoj zoni kao i regionalno tržište (npr. regionalno tržište A i potencijalna lokacija A) te je za ove slučajeve okvirna udaljenost određena kao 5 kilometara.

Na svakoj od potencijalnih lokacija skladišta, nalazi se odgovarajuće skladište. Međutim, troškovi iznajmljivanja skladišta za određenu lokaciju ovise o kapacitetu skladišnog prostora. Na svakoj lokaciji postoji tri različita tipa skladišta podijeljena po kapacitetu, kako je prikazano u tablici 2. Barem jedan oblik skladišta mora biti odabran na svakoj potencijalnoj lokaciji.

Tablica 2. Fiksni godišnji iznos iznajmljivanja (u EUR) i kapacitet skladišta (u hektolitrima)

Potencijalne lokacije skladišta	Skladište manjeg kapaciteta		Skladište srednjeg kapaciteta		Skladište većeg kapaciteta	
	Godišnji trošak iznajmljivanja (EUR)	Kapacitet (hektolitri)	Godišnji trošak iznajmljivanja (EUR)	Kapacitet (hektolitri)	Godišnji trošak iznajmljivanja (EUR)	Kapacitet (hektolitri)
A	48840,00	23760,00	56980,00	29700,00	73260,00	39600,00
B	50280,00	25920,00	58660,00	32400,00	75420,00	43200,00
C	53160,00	30240,00	62020,00	37800,00	79740,00	50400,00
D	54600,00	32400,00	63700,00	40500,00	81900,00	54000,00
E	47400,00	21600,00	55300,00	27000,00	71100,00	36000,00
F	51720,00	28080,00	60340,00	35100,00	77580,00	46800,00
G	53160,00	30240,00	62020,00	37800,00	79740,00	50400,00
H	54600,00	32400,00	63700,00	40500,00	81900,00	54000,00
I	47400,00	21600,00	55300,00	27000,00	71100,00	36000,00
J	48120,00	22680,00	56140,00	28350,00	72180,00	37800,00

Godišnja potražnja regionalnih tržišta za dva nova proizvoda je dana u tablici 3. U tablici 4. nalaze se troškovi rukovanja u skladištu koji se odnose na rad i opremu s proizvodima na njihovom ulazu i izlazu.

Tablica 3. Potražnja (hektolitri/godini) za regionalna tržišta za dva proizvoda

Tip proizvoda	Regionalna tržišta					
	A	B	F	G	I	J
1	11200,00	8000,00	6400,00	9600,00	8000,00	7200,00
2	14000,00	10000,00	8000,00	12000,00	10000,00	9000,00

Tablica 4.Troškovi rukovanja (EUR/hl) na potencijalnoj lokaciji skladišta

Potencijalne lokacije skladišta	Tip proizvoda	
	1	2
A	0,2	0,4
B	0,4	0,8
C	0,3	0,6
D	0,5	1,0
E	0,5	1,0
F	0,5	1,0
G	0,5	1,0
H	0,3	0,6
I	0,2	0,4
J	0,2	0,4

Obje vrste proizvoda se na jednak način dostavljaju na regionalna tržišta: korištenjem flote kamiona. Svaki kamion ima kapacitet od 150 hektolitara i trošak od 0,92 po kilometru. Firma posjeduje dovoljan broj kamiona koji su dostupni za distribuciju proizvoda. Ono što je važno za znati je kako se i povratna putovanja moraju uračunati u trošak. Primjerice, kako je udaljenost od potencijalnog skladišta iznajmljenog na potencijalnoj lokaciji A i regionalnog tržišta B 76,1 kilometar, transportni trošak je 2 x 76,1 x 0,92 =140,024 € za prijevoz 150 hektolitara.

Ono što je nužno napraviti je donijeti odluku o tome gdje i koja će se skladišta iznajmiti na taj način da se zadovolji potražnja uz minimalne troškove.

Studije su pokazale kako se analizom distribucijskih sustava mogu postići i uštede do 15 % pa će u nastavku biti ponuđena optimizacija zadane distribucijske mreže. [14]

5. PRIJEDLOG IZGRADNJE OPTIMALNE DISTRIBUCIJSKE MREŽE

U nastavku rada, na temelju analize iz prethodnog poglavlja, prikazana je optimizacija zadane distribucijske mreže, najprije matematičkim modelom a zatim i korištenjem programskog alata Solver.

5.1. Matematički model zadanog problema

Proučavanjem gornjeg zadanog problema, može se uočiti kako je zapravo problem odrediti na kojim potencijalnim lokacijama skladišta iznajmiti koje skladište (vezano uz veličinu) a da potražnja na regionalnim tržištima bude zadovoljena. Pritom se mora uzeti u obzir kako postoje dvije vrste proizvoda: tip 1 i tip 2.

Prema tome, prije kreiranja matematičkog modela, dobro je znati neke opće informacije o sustavu te načine označavanja:

i = potencijalna lokacija skladišta prigodno označeno brojevima

$$i=1,\ldots,10$$

j = regionalno tržište prigodno označeno slijedećim slovima abecede

$$j=1,\ldots 6$$

k = tip skladišta koje se dijeli po veličini: skladište manjeg, srednjeg i većeg kapaciteta

$$k=1,\ldots,3$$

n = tip proizvoda prigodno označeno brojevima:

$$n=1,\ 2$$

b_{jn} = potražnja u hektolitrima proizvoda n po godini za regionalno tržište j

Q_{ik}= kapacitet skladišta k na potencijalnoj lokaciji skladišta i u hektolitrima

f_{ik} = fiksna godišnja rata u eurima za skladište k na svakoj potencijalnoj lokaciji skladišta i

T_{ij}=transportni troškovi po hektolitru ovisni o udaljenosti između potencijalne lokacije skladišta i do regionalnog tržišta j a računaju se po formuli (formula je kreirana od strane autora, na način da se svako putovanje kamiona promatra i sa aspekta povrata te se udaljenost, iz tog razloga pomnoži sa 2 i zadanim troškom. Kako bi se dobio trošak po hektolitru, dobiveni iznos se mora podijeliti sa 150) :

$$T_{ij} = \frac{2 * d_{ij} * 0{,}92}{150}$$ [1]

d_{ij}= udaljenost (u km) između potencijalne lokacije skladišta i do regionalnog tržišta j

H_{in}= troškovi rukovanja u €/hl proizvoda n na potencijalnoj lokaciji skladišta i

Na osnovi tih općih informacija, može se kreirati matematički model koji je prikazan u nastavku.

Ukupni broj varijabli odlučivanja je 150, a one su slijedeće:

X_{ijn} = količina proizvoda tipa n poslana sa potencijalne lokacije skladišta i na regionalno tržište j

$i = 1,\ldots,10$

$j = 1,\ldots,6$

$n = 1,2$ (5.1.1.)

Pored toga, potrebno je uvesti binarnu varijablu odlučivanja koja određuje je li skladište k otvoreno na potencijalnoj lokaciji skladišta:

$$y_{ik} = \begin{cases} 1 \text{ Ako je skladište } \mathbf{k} \text{ iznajmljeno na potencijalnoj lokaciji } \mathbf{i} \\ 0 \text{ Inače} \end{cases}$$

$i = 1,\ldots,10$

$k = 1,\ldots,3$

$y_{ik} \in \{1,0\}$ (5.1.2.)

Što se tiče ograničenja modela, ukupno ih ima 32, ali ne računajući ograničenje za nemogućnosti negativnosti i ograničenje vezano za binarne varijable:

1. Samo jedan kapacitet se može izabrati na svakoj potencijalnoj lokaciji skladišta.

$$\sum_{k=1}^{3} y_{ik} \leq 1 \qquad i=1,\ldots,10 \qquad (5.1.3.)$$

2. Kapacitet izabranog skladišta na potencijalnoj lokaciji skladišta je ograničen i ne može biti prekoračen.

$$\sum_{j=1}^{6} \sum_{n=1}^{2} x_{ijn} \leq \sum_{k=1}^{3} y_{ik} * Q_{ik} \qquad i=1,\ldots,10 \qquad (5.1.4.)$$

[1] Formula je kreirana od strane autora, na način da se svako putovanje kamiona promatra i sa aspekta povrata te se udaljenost, iz tog razloga pomnoži sa 2 i zadanim troškom. Kako bi se dobio trošak po hektolitru, dobiveni iznos se mora podijeliti sa 150.

3. Potražnja mora biti jednaka količini proizvoda tipa n poslanog sa potencijalne lokacije skladišta i na regionalno tržište j, tako da je potražnja svih tržišta zadovoljena

$$\sum_{i=1}^{10} x_{ijn} = b_{jn} \qquad j=1,\ldots,6 \qquad n=1,2 \qquad (5.1.5.)$$

4. Nije moguće prevoziti negativni iznos proizvoda.

$$x_{ijn} \geq 0 \qquad i=1,\ldots,10 \qquad j=1,..,6 \quad n=1,2 \qquad (5.1.6.)$$

5. Ograničenje za binarne varijable

$$y_{ik} \in \{1,0\} \qquad i=1,\ldots,10 \quad k=1,\ldots,3 \qquad (5.1.7.)$$

Funkcija cilja je u funkciji minimiziranja ukupnih troškova (fiksnih, transportnih i troškova najma).

$$\text{Min } z = \sum_{i=1}^{10} \sum_{k=1}^{3} f_{ik} * y_{ik} + \sum_{i=1}^{10} \sum_{j=1}^{6} \sum_{n=1}^{2} T_{ij} * x_{ijn} + \sum_{i=1}^{10} \sum_{j=1}^{6} \sum_{n=1}^{2} H_{in} * x_{ijn}$$

5.2. Postavljanje modela u programski alat Excel Solver

Solver je dodatak Microsoft Excelu koji se koristi za *what-if* analize. Pomoću Solver-a moguće je pronaći optimalnu (maksimalnu ili minimalnu) vrijednost za formulu u jednoj ćeliji- koja se naziva ćelija cilja, podložne ograničenjima drugih ćelija. On radi sa grupom ćelija, nazvanih varijablama odlučivanja ili jednostavnije varijabilnim ćelijama koje se koriste za izračunavanje formula u ćeliji cilja i ćelijama ograničenja. Prilagođava vrijednosti u varijabilnim ćelijama kako bi zadovoljio ograničenja ćelija ograničenja i proizveo rezultat za ćeliju cilja. Jednostavno rečeno, Solver se koristi za određivanje maksimalne ili minimalne vrijednosti jedne ćelije promjenom drugih ćelija. Npr. može se promijeniti iznos projiciranog budžeta da se vidi utjecaj na projicirani profit.[15]

Cilj ove analize je odlučiti gdje iznajmiti skladišne prostore, na taj način da je potražnja svih regionalnih tržišta zadovoljena u svakom trenutku, a da su ukupni troškovi minimalizirani. Nakon postavljanja matematičkog modela prema realnom stanju, sve varijable odlučivanja, ograničenja i funkcije cilja postavljene su u Excel Solver.

Slijedeće tablice prikazuju postavljena ograničenja.

Tablica 5.Ograničenje vezano za broj skladišta na potencijalnoj lokaciji skladišta

Potencijalne lokacije skladišta	Broj iznajmljenih skladišta		Maksimalni broj iznajmljenih skladišta
A	1	<=	1
B	0	<=	1
C	1	<=	1
D	0	<=	1
E	0	<=	1
F	0	<=	1
G	1	<=	1
H	0	<=	1
I	0	<=	1
J	0	<=	1

Vrijednosti u desnom stupcu Tablice 5. su fiksno postavljene jer ovo ograničenje striktno određuje kako na svakoj potencijalnoj lokaciji skladišta ne može biti iznajmljeno više od jednog skladišta. Desni stupac tablice može sadržavati vrijednosti 0 ili 1. Vrijednost 1 znači da je Solver, na temelju zadanog mu ograničenja, odredio da je na toj potencijalnoj lokaciji otvoreno samo jedno skladište. Ako je vrijednost 0, Solverom je određeno kako na toj lokaciji nije uopće otvoreno skladište. Najam samo jednog skladišta na jednoj potencijalnoj lokaciji predstavlja logičan izbor jer bi iznajmljivanjem više skladišta na jednoj lokaciji jako porasli fiksni troškovi najma skladišta ali bi se povećala i razina zaliha jer bi svako od skladišta otvoreno na istoj potencijalnoj lokaciji moralo imati određenu minimalnu zalihu. Takav pristup bi mogao voditi naposljetku do postojanja nekurentnih zaliha odnosno onih koje nemaju velik koeficijent obrtaja i nakon određenog vremena postaju neupotrebljive. Budući je riječ o proizvodu, koje ima određeni rok trajanja, ovakav pristup mora biti posebno uzet u obzir.

Tablica 6. Ograničenje vezano za potražnju proizvoda tipa 1

Regionalna tržišta	Potražnja za tip proizvoda 1		
A	11200,00	=	11200,00
B	8000,00	=	8000,00
F	6400,00	=	6400,00
G	9600,00	=	9600,00
I	8000,00	=	8000,00
J	7200,00	=	7200,00

Tablica 7 .Ograničenje vezano za potražnju proizvoda tipa 2

Regionalna tržišta	Potražnja za tip proizvoda 2		
A	14000,00	=	14000,00
B	10000,00	=	10000,00
F	8000,00	=	8000,00
G	12000,00	=	12000,00
I	10000,00	=	10000,00
J	9000,00	=	9000,00

Ograničenja vezana za potražnju su jedna od najvažnijih, ako ne i najvažnija ograničenja. Visoka razina usluge kupcu mora, uz minimalne troškove, biti prvi i najvažniji cilj svake tvrtke. Ako se potražnja ne slaže s količinom koja je poslana na tržište iz skladišta, tvrtka je uvijek na gubitku. Ispunjenje potražnje je izuzetno važno jer ako kupac ne može dobiti robu u trenutku kada to želi, postoji rizik da će se okrenuti konkurentskom dobavljaču drugog proizvoda, te bi tako tvrtka mogla izgubiti svoje kupce. Također, svaki put kada bi kupac htio kupiti proizvod a nije ga pronašao u dućanu, predstavlja oportunitetni trošak, odnosno gubitak za tvrtku. Ograničenja u ovom slučaju prikazana su u Tablicama 6. i 7.

U slučaju da je količina koja je određena za određeno tržište veća od potraživane količine na tom tržištu, nastat će višak zaliha robe. Tu robu tvrtka mora držati na skladištu te tako svaki dan povećavati troškove tih zaliha.

Tablica 8. Ograničenje vezano za kapacitet

Potencijalne lokacije skladišta	Ukupni kapacitet za tip proizvoda 1 i 2		
A	39600,00	<=	39600,00
B	0,00	<=	0,00
C	37800,00	<=	37800,00
D	0,00	<=	0,00
E	0,00	<=	0,00
F	0,00	<=	0,00
G	36000,00	<=	37800,00
H	0,00	<=	0,00
I	0,00	<=	0,00
J	0,00	<=	0,00

Pri odlučivanju o izboru skladišta, kapacitet toga skladišta igra veliku ulogu. U radu su zadane tri vrste skladišta: manjeg, srednjeg i većeg kapaciteta. Kapacitet je fiksna varijabla, i on ne smije, odnosno ne može biti prekoračen. Vrijednosti 0 u Tablici 8. označavaju kako na toj potencijalnoj lokaciji nije otvoreno uopće skladište, pa samim time ne postoji nikakav kapacitet.

Temeljem zadanih ograničenja, korištenjem programskog alata Solvera dobivene su slijedeće varijable odlučivanja:

Tablica 9. Količina tipa proizvoda 1 poslana sa potencijalnih lokacija skladišta do regionalnih tržišta

Potencijalne lokacije skladišta	Regionalna tržišta					
	A	B	F	G	I	J
A	**7600,00**	0,00	**6400,00**	0,00	0,00	0,00
B	0,00	0,00	0,00	0,00	0,00	0,00
C	**3600,00**	0,00	0,00	0,00	**8000,00**	**7200,00**
D	0,00	0,00	0,00	0,00	0,00	0,00
E	0,00	0,00	0,00	0,00	0,00	0,00
F	0,00	0,00	0,00	0,00	0,00	0,00
G	0,00	**8000,00**	0,00	**9600,00**	0,00	0,00
H	0,00	0,00	0,00	0,00	0,00	0,00
I	0,00	0,00	0,00	0,00	0,00	0,00
J	0,00	0,00	0,00	0,00	0,00	0,00
Potražnja proizvoda 1	**11200,00**	**8000,00**	**6400,00**	**9600,00**	**8000,00**	**7200,00**

Tablica 10. Količina tipa proizvoda 2 poslana sa potencijalnih lokacija skladišta do regionalnih tržišta

Potencijalne lokacije skladišta	Regionalna tržišta					
	A	B	F	G	I	J
A	**14000,00**	**3600,00**	**8000,00**	0,00	0,00	0,00
B	0,00	0,00	0,00	0,00	0,00	0,00
C	0,00	0,00	0,00	0,00	**10000,00**	**9000,00**
D	0,00	0,00	0,00	0,00	0,00	0,00
E	0,00	0,00	0,00	0,00	0,00	0,00
F	0,00	0,00	0,00	0,00	0,00	0,00
G	0,00	**6400,00**	0,00	**12000,00**	0,00	0,00
H	0,00	0,00	0,00	0,00	0,00	0,00
I	0,00	0,00	0,00	0,00	0,00	0,00
J	0,00	0,00	0,00	0,00	0,00	0,00
Potražnja proizvoda 2	**14000,00**	**10000,00**	**8000,00**	**12000,00**	**10000,00**	**9000,00**

Tablica 11. Binarne varijable koje predstavljaju odabrani tip skladišta i odabranu potencijalnu lokaciju skladišta

Potencijalne lokacije skladišta	Skladište manjeg kapaciteta	Skladište srednjeg kapaciteta	Skladište većeg kapaciteta
A	0	0	1
B	0	0	0
C	0	1	0
D	0	0	0
E	0	0	0
F	0	0	0
G	0	1	0
H	0	0	0
I	0	0	0
J	0	0	0

Temeljem svih postavljenih ograničenja, varijabli i funkcije cilja koja bi trebala minimizirati ukupne troškove izabrana su skladišta prikazana u Tablici 11. Vrijednosti u Tablicama 9., 10. i 11. predstavljaju varijable odlučivanja. Vrijednost 0 u tim tablicama označava da na toj potencijalnoj lokaciji nije otvoreno skladište. Te vrijednosti su dobivene pomoću programskog alata Solvera, nakon što su mu zadana sva ograničenja i postavljena funkcija cilja.

Za izračun ukupnih troškova bilo je nužno odrediti i broj kamiona koji će prevoziti proizvode, a zatim prema tome izračunati transportne troškove od potencijalnih lokacija skladišta do regionalnih skladišta. Broj kamiona određen je na način da se zbrojila ukupna količina proizvoda koja se prevozi, a sa za svaku izabranu lokaciju i na svako regionalno tržište, te se podijeli sa 150 (broj hektolitara po jednom kamionu). Ukupna količina prikazana je u Tablici 12.

Tablica 12. Ukupna količina proizvoda 1 i 2 poslana od potencijalne lokacije skladišta do regionalnih tržišta

Potencijalne lokacije skladišta	Regionalna tržišta					
	A	B	F	G	I	J
A	**21600,00**	**3600,00**	**14400,00**	0,00	0,00	0,00
B	0,00	0,00	0,00	0,00	0,00	0,00
C	**3600,00**	0,00	0,00	0,00	**18000,00**	**16200,00**
D	0,00	0,00	0,00	0,00	0,00	0,00
E	0,00	0,00	0,00	0,00	0,00	0,00
F	0,00	0,00	0,00	0,00	0,00	0,00
G	0,00	**14400,00**	0,00	**21600,00**	0,00	0,00
H	0,00	0,00	0,00	0,00	0,00	0,00
I	0,00	0,00	0,00	0,00	0,00	0,00
J	0,00	0,00	0,00	0,00	0,00	0,00

Tablica 13. Broj kamiona koji voze od potencijalnih lokacija skladišta do regionalnih tržišta

Potencijalne lokacije skladišta	Regionalna tržišta					
	A	B	F	G	I	J
A	**144,00**	**24,00**	**96,00**	0,00	0,00	0,00
B	0,00	0,00	0,00	0,00	0,00	0,00
C	**24,00**	0,00	0,00	0,00	**120,00**	**108,00**
D	0,00	0,00	0,00	0,00	0,00	0,00
E	0,00	0,00	0,00	0,00	0,00	0,00
F	0,00	0,00	0,00	0,00	0,00	0,00
G	0,00	**96,00**	0,00	**144,00**	0,00	0,00
H	0,00	0,00	0,00	0,00	0,00	0,00
I	0,00	0,00	0,00	0,00	0,00	0,00
J	0,00	0,00	0,00	0,00	0,00	0,00

Tablica 14. Transportni troškovi za kamione koji voze od potencijalnih lokacija skladišta do regionalnih tržišta

Potencijalne lokacije skladišta	Regionalna tržišta					
	A	B	F	G	I	j
A	**1324,80**	**3360,58**	**5369,86**	0,00	0,00	0,00
B	0,00	0,00	0,00	0,00	0,00	0,00
C	**918,53**	0,00	0,00	0,00	**10488,00**	**2325,02**
D	0,00	0,00	0,00	0,00	0,00	0,00
E	0,00	0,00	0,00	0,00	0,00	0,00
F	0,00	0,00	0,00	0,00	0,00	0,00
G	0,00	**13636,61**	0,00	**1324,80**	0,00	0,00
H	0,00	0,00	0,00	0,00	0,00	0,00
I	0,00	0,00	0,00	0,00	0,00	0,00
J	0,00	0,00	0,00	0,00	0,00	0,00

Nakon obavljenog izračuna, dobiveno je rješenje prikazano u Tablici 11. na način da je potražnja za svako regionalno tržište i za svaki proizvod zadovoljena (Tablica 9 i Tablica 10.). Koriste se:

- Skladište većeg kapaciteta na lokaciji A koje skladišti 14 000 hektolitara za tip proizvoda 1 i 25 600 hektolitara za tip proizvoda 2
- Skladište srednjeg kapaciteta na lokaciji C koje skladišti 18 800 hektolitara za tip proizvoda 1 i 19 000 hektolitara za tip proizvoda 2
- Skladište srednjeg kapaciteta na lokaciji G koje skladišti 17 600 hektolitara za tip proizvoda 1 i 18 400 za tip proizvoda 2.

Prema tome, izračunati su slijedeći troškovi koji su prikazani u tablici 14.

Tablica 15. Ukupni troškovi- funkcija cilja

UKUPNI TROŠKOVI	**293.328,19 EUR**
Fiksni troškovi	197.300,00 EUR
Transportni troškovi	38.748,19 EUR
Troškovi rukovanja robom	57.280,00 EUR

U distribuciji proizvoda nužno je postići dobar omjer između efikasnosti i efektivnosti. Drugim riječima, smanjenje ukupnih troškova ne bi smjelo utjecati na razinu usluge prema krajnjem korisniku.

Jedan od važnijih parametara kad je u pitanju usluga krajnjem korisniku je brzina odgovora na potražnju. U ovom slučaju imamo šest regionalnih tržišta i 10 potencijalnih lokacija za skladišta koja će opskrbljivati ta tržišta. Funkcija cilja se vodi konačnim ciljem smanjenja ukupnih troškova uz zadovoljenje ograničenja kapaciteta i potražnje. No, što se dogodi kada menadžeri žele dodatno poboljšati uslugu i smanjiti udaljenost između skladišta i tržišta? O udaljenosti kao veoma važnom parametru bit će riječi više u nastavku rada.

5.3. Optimizacija distribucijske mreže s uvođenjem ograničenja za udaljenost

Nakon analiziranja dobivenog početnog scenarija, uviđa se kako su neka regionalna tržišta udaljena od lokacije skladišta koje je zaduženo za usluživanje njihove potražnje. To u značajnoj mjeri može utjecati na brzinu odgovora na potražnju tržišta, što naposljetku bitno utječe na razinu usluge.

U narednom dijelu rada, sa svrhom poboljšanja razine usluge, postavit će se ograničenje od 60 kilometara vezano za udaljenost između tržišta i skladišta koje ga opslužuje.

Kako bi se u Excel Solveru u ovom slučaju dobilo optimalnu distribucijsku mrežu s obzirom na maksimalnu udaljenost od 60 kilometara, nužno je koristiti naredbu IF te postaviti slijedeće: if udaljenost $\leq$ 60, izaberi udaljenost iz Tablice 1., u suprotnom izaberi nasumično odabran veliki broj (u ovom slučaju 10000- korištenje nasumično odabranog velikog broja najlakši je način jer je logična pretpostavka kako se neće upotrijebiti nikada tako velika vrijednost jer se traži optimalno rješenje). U tom slučaju, za računanje troškova prijevoza od potencijalnih lokacija skladišta do regionalnih tržišta koristi se novokreirana Tablica 15.

Tablica 16. Udaljenost (u km) između potencijalnih lokacija skladišta i regionalnih tržišta koristeći funkciju IF

Potencijalne lokacije skladišta	Regionalna tržišta					
	A	B	F	G	I	J
A	5,00	10000,00	30,40	10000,00	10000,00	11,70
B	10000,00	5,00	10000,00	10000,00	10000,00	10000,00
C	20,80	10000,00	47,20	10000,00	47,50	11,70
D	54,70	10000,00	52,90	10000,00	10000,00	45,20
E	13,50	10000,00	28,00	10000,00	10000,00	9,30
F	30,40	10000,00	5,00	10000,00	10000,00	38,10
G	10000,00	10000,00	10000,00	5,00	10000,00	10000,00
H	47,80	10000,00	46,20	10000,00	10000,00	38,90
I	10000,00	10000,00	10000,00	10000,00	5,00	10000,00
J	11,70	10000,00	38,10	10000,00	10000,00	5,00

Tablica 17. Količina tipa proizvoda 1 poslana sa potencijalnih lokacija skladišta do regionalnih tržišta obzirom na ograničenje o udaljenosti

Potencijalne lokacije skladišta	Regionalna tržišta					
	A	B	F	G	I	J
A	0,00	0,00	**1760,00**	0,00	0,00	0,00
B	0,00	**8000,00**	0,00	0,00	0,00	0,00
C	**11200,00**	0,00	**4640,00**	0,00	**8000,00**	**7200,00**
D	0,00	0,00	0,00	0,00	0,00	0,00
E	0,00	0,00	0,00	0,00	0,00	0,00
F	0,00	0,00	0,00	0,00	0,00	0,00
G	0,00	0,00	0,00	**9600,00**	0,00	0,00
H	0,00	0,00	0,00	0,00	0,00	0,00
I	0,00	0,00	0,00	0,00	0,00	0,00
J	0,00	0,00	0,00	0,00	0,00	0,00
Potražnja proizvoda 1	**11200,00**	**8000,00**	**6400,00**	**9600,00**	**8000,00**	**7200,00**

Tablica 18. Količina tipa proizvoda 2 poslana sa potencijalnih lokacija skladišta do regionalnih tržišta obzirom na ograničenje o udaljenosti

Potencijalne lokacije skladišta	Regionalna tržišta					
	A	B	F	G	I	J
A	**14000,00**	0,00	**8000,00**	0,00	0,00	0,00
B	0,00	**10000,00**	0,00	0,00	0,00	0,00
C	0,00	0,00	0,00	0,00	**10000,00**	**9000,00**
D	0,00	0,00	0,00	0,00	0,00	0,00
E	0,00	0,00	0,00	0,00	0,00	0,00
F	0,00	0,00	0,00	0,00	0,00	0,00
G	0,00	0,00	0,00	**12000,00**	0,00	0,00
H	0,00	0,00	0,00	0,00	0,00	0,00
I	0,00	0,00	0,00	0,00	0,00	0,00
J	0,00	0,00	0,00	0,00	0,00	0,00
Potražnja proizvoda 2	**14000,00**	**10000,00**	**8000,00**	**12000,00**	**10000,00**	**9000,00**

Tablica 19. Binarne varijable koje predstavljaju odabrani tip skladišta i odabranu potencijalnu lokaciju skladišta uz ograničenje udaljenosti od 60 km

Potencijalne lokacije skladišta	Skladište manjeg kapaciteta	Skladište srednjeg kapaciteta	Skladište velikog kapaciteta
A	**1**	0	0
B	**1**	0	0
C	0	0	**1**
D	0	0	0
E	0	0	0
F	0	0	0
G	**1**	0	0
H	0	0	0
I	0	0	0
J	0	0	0

Vrijednosti u Tablicama 17., 18. i 19. predstavljaju varijable odlučivanja. Vrijednost 0 u tim tablicama označava da na toj potencijalnoj lokaciji nije otvoreno skladište. Te vrijednosti su dobivene pomoću Solvera u kojem su, uzimajući u obzir sva zadana ograničenja i funkciju cilja generirana rješenja.

Prema tome, potreban broj kamiona i troškovi prijevoza nalaze se u sljedeće dvije tablice, a dobiveni su na isti način kao i podaci u Tablicama 13. i 14. ali ovaj put uzimajući u obzir ograničenje od 60 kilometara.

Tablica 20. Broj kamiona koji voze od potencijalnih lokacija skladišta do regionalnih tržišta obzirom na ograničenje o udaljenosti

Potencijalne lokacije skladišta	Regionalna tržišta					
	A	B	F	G	I	j
A	**93,33**	0,00	**65,07**	0,00	0,00	0,00
B	0,00	**120,00**	0,00	0,00	0,00	0,00
C	**74,67**	0,00	**30,93**	0,00	**120,00**	**108,00**
D	0,00	0,00	0,00	0,00	0,00	0,00
E	0,00	0,00	0,00	0,00	0,00	0,00
F	0,00	0,00	0,00	0,00	0,00	0,00
G	0,00	0,00	0,00	**144,00**	0,00	0,00
H	0,00	0,00	0,00	0,00	0,00	0,00
I	0,00	0,00	0,00	0,00	0,00	0,00
J	0,00	0,00	0,00	0,00	0,00	0,00

Tablica 21. Transportni troškovi za kamione koji voze od potencijalnih lokacija skladišta do regionalnih tržišta obzirom na ograničenje o udaljenosti

Potencijalne lokacije skladišta	Regionalna tržišta					
	A	B	F	G	I	J
A	**858,67**	0,00	**3639,57**	0,00	0,00	0,00
B	0,00	**1104,00**	0,00	0,00	0,00	0,00
C	**2857,64**	0,00	**2686,50**	0,00	**10488,00**	**2325,02**
D	0,00	0,00	0,00	0,00	0,00	0,00
E	0,00	0,00	0,00	0,00	0,00	0,00
F	0,00	0,00	0,00	0,00	0,00	0,00
G	0,00	0,00	0,00	**1324,80**	0,00	0,00
H	0,00	0,00	0,00	0,00	0,00	0,00
I	0,00	0,00	0,00	0,00	0,00	0,00
J	0,00	0,00	0,00	0,00	0,00	0,00

Postavljanjem maksimalne udaljenosti na 60 kilometara, optimalna distribucijska mreža se promijenila na taj način da se sada, za zadovoljenje potražnje, moraju unajmiti 4 skladišta i to redom:

- Skladište manjeg kapaciteta na lokaciji A koje skladišti 1760 hektolitara za tip proizvoda 1 i 22 000 hektolitara za tip proizvoda 2
- Skladište manjeg kapaciteta na lokaciji B koje skladišti 8 000 hektolitara za tip proizvoda 1 i 10 000 hektolitara za tip proizvoda 2
- Skladište većeg kapaciteta na lokaciji C koje skladišti 31 040 hektolitara za tip proizvoda 1 i 19 000 za tip proizvoda 2.
- Skladište većeg kapaciteta na lokaciji G koje skladišti 9 600 hektolitara za tip proizvoda 1 i 12 000 za tip proizvoda 2.

Prema tome, izračunati su slijedeći troškovi koji su prikazani u tablici 20.

Tablica 22. Ukupni troškovi- funkcija cilja obzirom na ograničenje o udaljenosti (60km)

FUNKCIJA CILJA	315.168,20 EUR
Fiksni troškovi	232.020,00 EUR
Transportni troškovi	25.284,20 EUR
Troškovi rukovanja robom	57.864,00 EUR

Smanjenjem udaljenosti između potencijalne lokacije skladišta i regionalnih tržišta smanjivali bi se i transportni troškovi jer manja udaljenost znači brži i kraći prijevoz robe do tržišta. Istovremeno dolazi do povećanja fiksnih troškova skladišta (fij) i to u toliko mjeri, da je trenutna optimalna distribucijska mreža skuplja u odnosu na početnu za 21 840,01 EUR. U prvom rješenju bila su nužna samo tri skladišta u odnosu na ovo rješenje u kojem su potrebna četiri skladišta.

Sa smanjenjem maksimalne udaljenosti na 40 km, broj iznajmljenih skladišta se dodatno povećao pa tako tada imamo otvorenih pet skladišta (Tablica 21.). S druge strane, transportni troškovi su se dodatno smanjili, ali su ukupni troškovi porasli. U odnosu na prvo rješenje, ukupni troškovi su veći za 33 847,31 EUR, a u odnosu na drugo su veći za 12 007,3, što dodatno potvrđuje teoriju kako troškovi sa smanjenjem udaljenosti rastu.

Tablica 23. Ukupni troškovi- funkcija cilja obzirom na ograničenje o udaljenosti (40km)

FUNKCIJA CILJA	327.175,50 EUR
Fiksni troškovi	263.960,00 EUR
Transportni troškovi	12.255,50 EUR
Troškovi rukovanja robom	50.960,00 EUR

Tablica 24. Binarne varijable koje predstavljaju odabrani tip skladišta i odabranu potencijalnu lokaciju skladišta uz ograničenje udaljenosti od 40 km

Potencijalne lokacije skladišta	Skladište manjeg kapaciteta	Skladište srednjeg kapaciteta	Skladište velikog kapaciteta
A	0	**1**	0
B	**1**	0	0
C	0	0	0
D	0	0	0
E	0	0	0
F	0	0	0
G	**1**	0	0
H	0	0	0
I	**1**	0	0
J	0	**1**	0

5.4. Dodatno o optimizaciji distribucijskih procesa u tvrtki

Postavljanjem modela najprije matematički, a zatim i u programskom alatu Solver, dobila su se rješenja koja bi trebala biti optimalna. No prilikom dizajniranja distribucijske mreže nužno je voditi računa i o nekim drugim elementima.

Udaljenost između određenog skladišta i regionalnog tržišta koje skladište opskrbljuje: skladištiti proizvod što bliže korisniku je veoma važno jer omogućava brz i promptan odgovor na potražnju odnosno isporuku. U konačnici to utječe i na transportne troškove. Teorija je dokazana u prethodnom dijelu rada ali je ukazala i na to da ovaj pristup u konačnici povećava troškove radi povećanja broja skladišta.

Također, važno je znati i o samom potencijalnom skladištu: nudi li skladište možda željeznički kolosijek u blizini ili neki drugi oblik prometa? Postoji li možda neka dodatna oprema uključena u cijenu? Također, ako potražnja za proizvodima ima određene sezonske fluktuacije, može li lokacija ponuditi veći ili manji skladišni prostor, ovisno o vremenu u godini? Postoji li financijska prednost unajmljivanja skladišta na duže vremensko razdoblje? Također, veoma bitna stavka za konkretno ovaj slučaj je ta može li skladište ponuditi odgovarajuće uvjete skladištenja (zahtjevi vezani uz temperaturni režim ako je riječ o proizvodu ograničenog vijeka trajanja)? Pića, kao prehrambeni proizvod, zahtijevaju poseban pristup u skladištenju. Ne smiju se izlagati pretjeranoj svjetlosti, skladištenje bi trebalo biti u tamnijem prostoru. Njihova ambalaža, ukoliko je staklena, podložna je pucanju radi nepravilnog rukovanja i slično.

Osim toga, važnu ulogu za budući razvoj tvrtke igra i odabir odgovarajuće radne snage. Postoji li na izabranoj lokaciji dovoljno obrazovnih ljudi i radno sposobnih ljudi za rad u skladištu? Također, postoji li potreba za drugom ili trećom smjenom (rad 24 sata). Postoje li konkurentske tvrtke u blizini koje mogu utjecati i ograničiti dostupnost odgovarajuće radne snage? Osim toga, cijena radno sposobnog osoblja nije ista na svim područjima. Kao posljedica globalizacije je slučaj u kojem velike tvrtke svoja postrojenja smještaju u siromašnije zemlje gdje je dostupna puno jeftinija radna snaga nego u matičnoj zemlji.

Pojedina područja u sklopu razvoja regije nude dodatne poticaje za poduzetnike koji se odluče na otvaranje pogona/skladišta u njihovoj regiji. Nužno je istražiti sve pogodnosti koje pojedina lokacija nosi.

U blizini regija koje imaju veliku i stabilnu potražnju koja, prema povijesnim podacima, ima tendenciju porasta, trebalo bi se razmisliti o kupnji skladišnog prostora umjesto najma. Takav potez dugoročno bi se mogao pokazati isplativijim nego najam.

Izuzetno je puno izazova i pitanja s kojima se logistički stručnjaci moraju suočiti prilikom kreiranja optimalne distribucijske mreže. Koristiti možda vlastita vozila ili vanjskog davatelja usluga, gdje smjestiti skladišta i u kojem broju ali i pitanje kupnje ili najma skladišta.

No danas, distribucijske mreže, koliko god bile zamršenije nego prije, imaju potencijal veće optimizacije. Postojanje takozvanih Big Data, omogućava menadžerima pristup nevjerojatno velikom broju podataka. Big Data predstavljaju kombinaciju tehnologija koje omogućuju povezivanje naizgled nepovezanih strukturiranih i nestrukturiranih podataka u realnom vremenu. Također, uz to se promatra brzina i obujam prikupljanja tih podataka s ciljem generiranja najtočnijih informacija vezanih za određeno područje istraživanja. Menadžeri mogu proučavati ne samo jedan, nego veći broj potencijalnih scenarija ali i integrirati svoje analize s mnogim drugim međusobno povezanim sustavima. Tvrtke koje koriste Big Data i napredne analitike za pojednostavljenje distribucijskih mreža obično postižu uštede koje se kreću od 10 do 20 posto troškova vezanih za robu i skladištenje, istodobno postižući velike uštede u zalihama. [16]

6. ZAKLJUČAK

Veličina distribucijske mreže može značajno varirati, počevši od distribucijske mreže jako male tvrtke pa sve do tvrtke koja robu isporučuje na globalnoj razini. Zajedničko svim tvrtkama, neovisno o veličini ili proizvodu odnosno usluzi koju nude, jest postaviti optimalnu distribucijsku mrežu.

O pojmu optimalno bi se, međutim, dalo raspravljati. Postoje tvrtke koje, kao u radu navedena Zara, više računa vode o brzoj i efikasnoj isporuci robe koja podliježe možda većim nestabilnostima u potražnji i većim transportnim troškovima, nego recimo u drugom slučaju određena tvrtka koja ima manje učestale isporuke i samim time manje troškove transporta. Optimalnom mrežom bi se mogla nazvati ona distribucijska mreža u kojoj je uz minimalne troškove postignuta najveća moguća razina usluge krajnjem korisniku. Problem optimizacije star je koliko i postojanje tvrtki. Različiti stručnjaci tom problemu pristupaju sa različitih aspekata. Tako postoji, u radu opisani, matematički pristup optimizaciji distribucijske mreže. Razvijeni su razni matematički modeli, koji koristeći parametre poput ograničenja i varijabli odlučivanja donose optimalni rezultat, takozvanu funkciju cilja. Prije samog postavljanja modela veoma je važno proučiti stvarni sustav kako bi znali sve njegove osobnosti ali i izazove s kojima se može suočiti. S napretkom tehnologije, matematički modeli su se polako počeli preslikavati u računalna okruženja pa danas tako imamo mogućnost, pomoću programskih alata, dobiti okvirnu sliku optimalne distribucijske mreže. Jedan od njih je i Solver, dodatak Microsoft Excelu, koji na temelju postavljenih varijabli i ograničenja donosi rezultat ali u računalnom okruženju.

Kao što je vidljivo u praktičnom primjeru iz rada, postoji mnogo stvari o kojima se mora voditi računa prilikom dizajna distribucijske mreže. Svako potencijalno skladište ima ograničeni kapacitet, a birajući ono s većim kapacitetom biramo i veću cijenu najma. Potražnja različitih tržišta mora biti zadovoljena što predstavlja ograničenje vezano za kapacitet: iznajmiti toliki broj skladišta koji će svojim kapacitetom zadovoljiti potrebe potražnje, ali prouzrokovati i minimalne troškove. Nadalje, kada u igru dođe još dodatnih ograničenja kao što je, u radu postavljeno ograničenje vezano za udaljenost, optimalna distribucijska mreža poprima drugačiji oblik. Sama optimizacija zapravo ovisi o preferencijama same tvrtke: hoće li se tvrtka fokusirati samo na smanjenje troška i pritom potencijalno ugroziti razinu usluge ili će iznajmiti veći broj skladišta, smanjiti vrijeme dostave krajnjem korisniku ali i povećati fiksne troškove? Rezultati u radu pokazuju, da iako postoji određeno smanjenje transportnih troškova s povećanjem broja skladišta, povećanje fiksnih troškova najma je toliko naraslo da su ukupni troškovi u konačnici

veći.

Optimirana distribucijska mreža je podložna promjenama. Ona je odličan temelj za donošenje daljnjih odluka. Menadžeri u firmi, kao što je navedeno u radu, moraju voditi računa i o drugim faktorima: potencijalni najam ili kupnja skladišta, dostupnost i spremnost na rad odgovarajuće radne snage, nude li određene lokacije neke prednosti u odnosu na druge, blizina najbitnijih prometnih pravaca i slično.

Danas tvrtke raspolažu s nevjerojatnom količinom podataka i velikom brzinom obrade tih podataka. Ono što je bitno kod optimizacije je da postoji jasno definirani cilj, a da se na temelju toga cilja odrede koraci do izgradnje odgovarajuće distribucijske mreže.

POPIS LITERATURE

[1] Shah,J. : Supply Chain Management: Text and cases, Indian Institute of Management, 2009.

[2] Crum, Colleen, Palmatier, G.: Demand Collaboration: What's Holding Us Back; Supply Chain Managemet review, 2004.

[3] Chopra, S. i Meindl, P. : Supply Chain Management: Strategy, Planning and Operation, 4th Edition, New Jersey, 2010.

[4] Robinson, A.: The Evolution and History of Supply Chain Management, 2015.

[5] Ivaković Č., Stanković R., Šafran M.: Špedicija i logistički procesi, Sveučilište u Zagrebu, 2010.

[6] Sabatah, R.E., Fontanella, J.: The Unfulfilled Promise of Supply Chain Collaboration; Supply Chain Management Review, 2002.

[7] Gallaughar, J.: Zara case: Fast Fashion From Savvy Systems. PhD Case, 2008.

[8] https://progressivewritingskills.wordpress.com/2015/04/28/logistics-management-of-zara-a-case-study/ , (siječanj, 2018.)

[9] Zhelyazkov, G.: Agile Supply Chain: Zara's case study analysis, 2012.

[10] Pankaj, G. i Nueno, J.L.: Zara: Fast Fashion, Harvard Business School, 2006.

[11] Pašagić, H.: Matematičko modeliranje i teorija grafova, Zagreb, 1998.

[12] Hillier, F.S., Lieberman G.J.: Introduction to Operations Research, Seventh Edition, 2001.

[13] Autorizirana predavanja iz kolegija „Advanced Operations Reserach“, Hochschule fuer Technik und Wirtschaft des Saarlandes, 2017.

[14] http://www.supplychain247.com/article/6_tips_for_optimizing_your_distribution_network, (siječanj, 2018.)

[15] https://products.office.com/hr-hr/home, (siječanj, 2018)

[16] Kotlik, L., Greiser, C., Brocca, M.: Making Big Data Work: Supply Chain Management, 2015.

POPIS SLIKA

Slika 1. Prikaz opskrbnog lanca 4
Slika 2. Odnos između željenog vremena odgovora i broja lokacija skladišta 9
Slika 3. Odnos između broja lokacija skladišta i troškova zaliha 9
Slika 4. Odnos logističkih troškova u odnosu na vrijeme odgovora i broj lokacija.....10
Slika 5. Proces modeliranja.....19
Slika 6. Potencijalne lokacije skladišta i regionalna tržišta 28

POPIS TABLICA

Tablica 1. Udaljenost (u km) između potencijalnih lokacija skladišta i regionalnih tržišta 27
Tablica 2. Fiksni godišnji iznos iznajmljivanja (u EUR) i kapacitet skladišta (u hektolitrima) ...29
Tablica 3. Potražnja (hektolitri/godini) za regionalna tržišta za dva proizvoda.....29
Tablica 4.Troškovi rukovanja (EUR/hl) u potencijalnoj lokaciji skladišta.....30
Tablica 5.Ograničenje vezano za broj skladišta na potencijalnoj lokaciji skladišta 34
Tablica 6. Ograničenje vezano za potražnju proizvoda tipa 1 35
Tablica 7 .Ograničenje vezano za potražnju proizvoda tipa 2 35
Tablica 8. Ograničenje vezano za kapacitet.....36
Tablica 9.Količina tipa proizvoda 1 poslana sa potencijalnih lokacija skladišta do regionalnih tržišta.....36
Tablica 10. Količina tipa proizvoda 2 poslana sa potencijalnih lokacija skladišta do regionalnih tržišta.....37
Tablica 11. Binarne varijable koje predstavljaju odabrani tip skladišta i odabranu potencijalnu lokaciju skladišta.....37
Tablica 12. Ukupna količina proizvoda 1 i 2 poslana od potencijalne lokacije skladišta do regionalnih tržišta.....38
Tablica 13. Broj kamiona koji voze od potencijalnih lokacija skladišta do regionalnih tržišta....38
Tablica 14. Transportni troškovi za kamione koji voze od potencijalnih lokacija skladišta do regionalnih tržišta.....39
Tablica 15. Ukupni troškovi- funkcija cilja 39
Tablica 16. Udaljenost (u km) između potencijalnih lokacija skladišta i regionalnih tržišta koristeći funkciju IF 41
Tablica 17. Količina tipa proizvoda 1 poslana sa potencijalnih lokacija skladišta do regionalnih tržišta obzirom na ograničenje o udaljenosti.....42
Tablica 18. Količina tipa proizvoda 2 poslana sa potencijalnih lokacija skladišta do regionalnih tržišta obzirom na ograničenje o udaljenosti.....42
Tablica 19. Binarne varijable koje predstavljaju odabrani tip skladišta i odabranu potencijalnu lokaciju skladišta uz ograničenje udaljenosti od 60 km.....43
Tablica 20. Broj kamiona koji voze od potencijalnih lokacija skladišta do regionalnih tržišta obzirom na ograničenje o udaljenosti.....44
Tablica 21. Transportni troškovi za kamione koji voze od potencijalnih lokacija skladišta do regionalnih tržišta obzirom na ograničenje o udaljenosti 44

Tablica 22. Ukupni troškovi- funkcija cilja obzirom na ograničenje o udaljenosti (60km) 45
Tablica 23. Ukupni troškovi- funkcija cilja obzirom na ograničenje o udaljenosti (40km) 46
Tablica 24. Binarne varijable koje predstavljaju odabrani tip skladišta i odabranu potencijalnu lokaciju skladišta uz ograničenje udaljenosti od 40 km.....46

Sveučilište u Zagrebu
Fakultet prometnih znanosti
10000 Zagreb
Vukelićeva 4

IZJAVA O AKADEMSKOJ ČESTITOSTI I SUGLASNOST

Izjavljujem i svojim potpisom potvrđujem kako je ovaj diplomski rad isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu što pokazuju korištene bilješke i bibliografija.

Izjavljujem kako nijedan dio rada nije napisan na nedozvoljen način, niti je prepisan iz necitiranog rada, te nijedan dio rada ne krši bilo čija autorska prava.

Izjavljujem također, kako nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Svojim potpisom potvrđujem i dajem suglasnost za javnu objavu diplomskog rada pod naslovom **Optimizacija distribucijske mreže u tvrtki**

na internetskim stranicama i repozitoriju Fakulteta prometnih znanosti, Digitalnom akademskom repozitoriju (DAR) pri Nacionalnoj i sveučilišnoj knjižnici u Zagrebu.

U Zagrebu, 20.4.2018

Student/ica:

Ana U.

(potpis)