Kristina Šorić

Uvod u upravljanje lancem opskrbe

Zagreb, 2022

ISBN 978-953-49497-3-3

Uvod u upravljanje lancem opskrbe
Kristina Šorić
Vlastita naklada autorice
www.luyouma.com
Ilustracija na naslovnici: Kristina Šorić
Sva prava pridržana. Nijedan dio ove knjige ne može biti objavljen ili otisnut bez prethodne suglasnosti nakladnika i vlasnika autorskih prava.
ISBN 978-953-49497-3-3
Zagreb, 2022.

1. Općenito o lancu opskrbe

1.1. Uvod

Što je lanac opskrbe? Koja vam je prva asocijacija kad čujete taj termin? Logistika, nabava, planiranje?

Kako su se pojedina poduzeća organizirala? Na sljedećoj je slici dan primjer strukture lanca opskrbe jednog proizvodnog poduzeća.

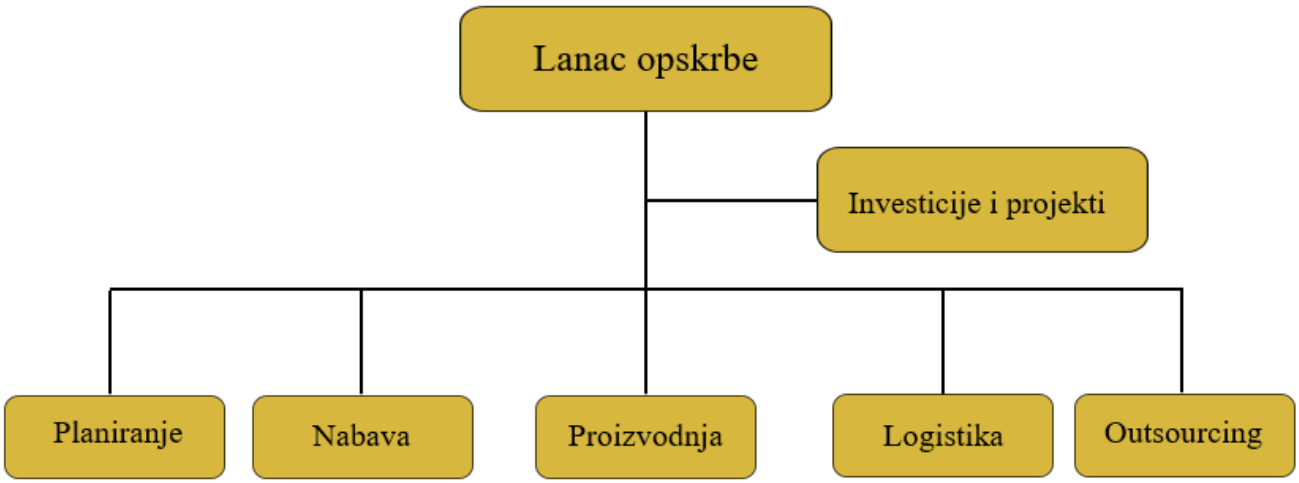

Nadalje, primjer strukture lanca opskrbe jednog trgovačkog lanca dana je dolje.

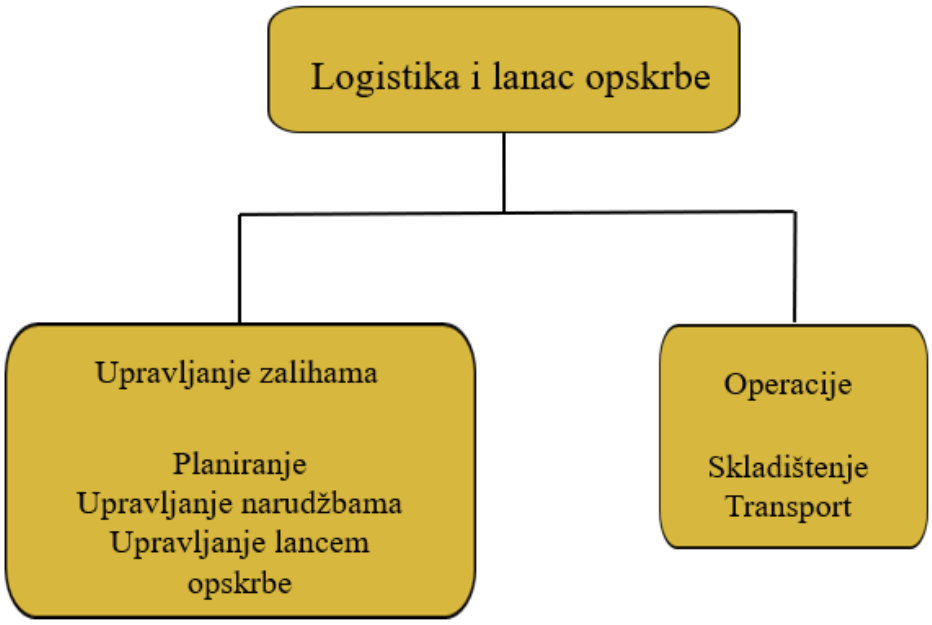

Neka poduzeća imaju strukturu ciklusa opskrbe jer su uključila i povratnu logistiku.

Koje su hijerarhijski više pozicije povezane s lancem opskrbe? U nekim je poduzećima direktor lanca opskrbe član uprave, u nekima ulogu direktora lanca opskrbe ima član uprave za financije i nabavu ili član uprave za tehničke operacije. U nekim poduzećima postoji direktor lanca opskrbe, ali nije član uprave. Kod nekih postoji član uprave za financije i logistiku. Uglavnom, različita poduzeća različito organiziraju svoje lance opskrbe, različito ih nazivaju, a i pozicije vezane uz lanac opskrbe su različite. Ne postoji jedinstvena struktura i jedinstvena pozicija. To ovisi o pojedinom poduzeću i djelatnosti kojom se to poduzeće bavi.

Koje su hijerarhijski niže pozicije povezane s lancem opskrbe? Primjeri koji se mogu pronaći su: specijalist lanca opskrbe, projektni suradnik za lanac opskrbe, planer potražnje, planer ponude, planer zaliha, analitičar poslovnih procesa za lanac opskrbe, koordinator lanca opskrbe i slično.

Kod opisa njihovih poslova, najčešće se traže ovi elementi: pregovaranje nabavnih uvjeta, pronalaženje najboljih dobavljača u skladu s kriterijima poduzeća, održavanje i unapređivanje odnosa s dobavljačima, kontrola, analiza i optimizacija troškova nabave i logistike, optimizacija zaliha, upravljanje (predviđanje i analiza) potražnjom, mjerenje ostvarivanja ciljeva lanca opskrbe, unapređenje S&OP (Sales and Operations Planning) procesa, koordinacija lanca opskrbe i slično.

U poslovnoj je praksi jednom jedan natječaj u opisu radnog mjesta direktora lanca opskrbe naveo da ta osoba mora biti istinsko ljepilo u organizaciji povezujući ljude, procese i različite odjele. A zašto? Zato da bi lanac opskrbe dobro balansirao između **efikasnosti** (učinkovitosti) i **efektivnosti** (djelotvornosti). Ili, zato da bi lanac opskrbe uz minimalne troškove isporučivao visoku razinu kvalitete. I to je ono što se događa u svakom lancu, balansiranje na kontinuumu između efikasnosti i efektivnosti. Ne postoji neki recept kako to provoditi, svako poduzeće ima svoju strategiju.

A tome onda služe strategije lanca opskrbe.

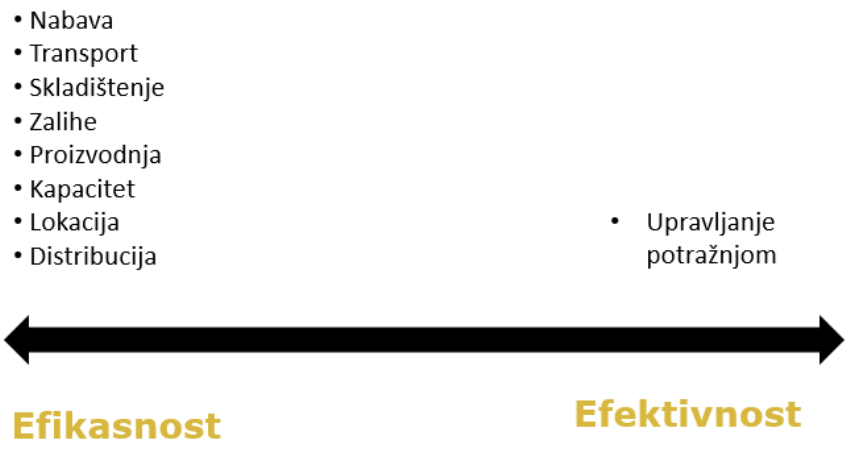

Pored strategija lanca opskrbe, jako je važno da je lanac integriran i koordiniran, da članovi lanca komuniciraju i surađuju. U protivnom, ne možemo govoriti o lancu opskrbe. I tako dolazimo do definicije lanca opskrbe.

1.2. Definicija lanca opskrbe

Postoje različite definicije lanca opskrbe, a ovdje ćemo se služiti ovom:

> **Lanac opskrbe je koordinirani sustav protoka materijala, usluga i informacija od dobavljača do kupca.**

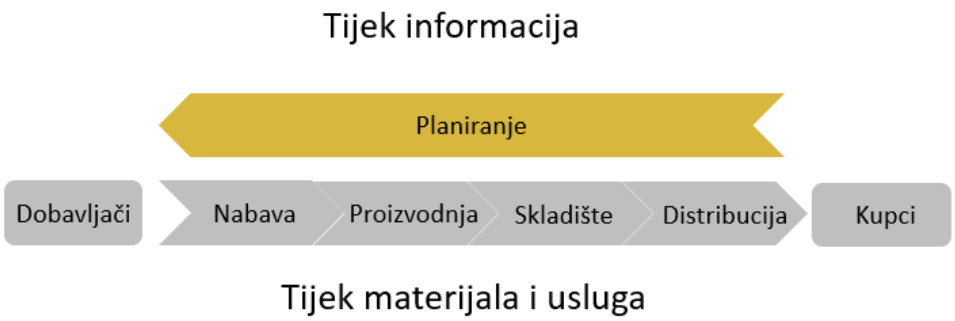

Da bismo potpuno shvatili definiciju lanca opskrbe, važno je znati njegov razvoj. Na sljedećoj je slici prikazan isti.

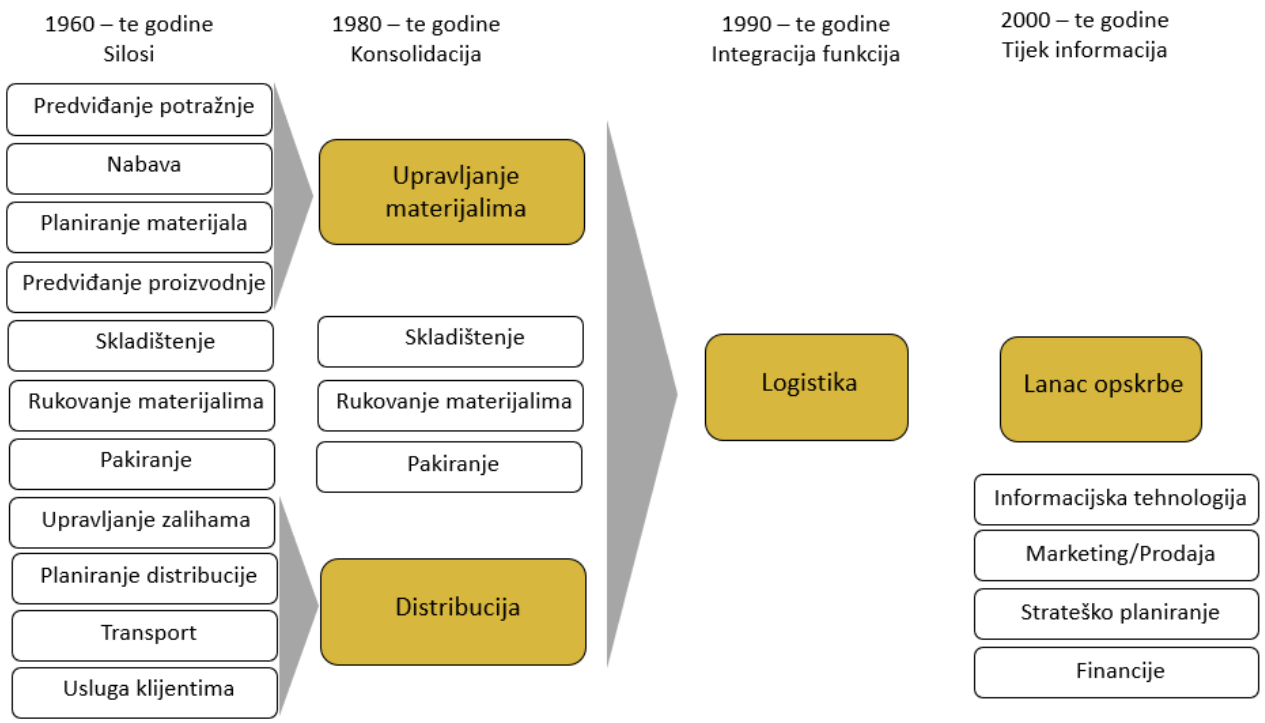

https://transportgeography.org/?page_id=4438

1.3. Definicija upravljanja lancem opskrbe

Već smo naveli da lanac opskrbe balansira između **efikasnosti** (učinkovitosti) i **efektivnosti** (djelotvornosti). I pritom koristi strategije lanca opskrbe. Također, postoje različite definicije upravljanja lancem opskrbe, a mi ćemo koristiti ovu:

Upravljanje lancem opskrbe je

integracija

dobavljača, proizvođača, skladišta i prodajnih mjesta

u svrhu proizvodnje i distribucije robe u

pravim količinama, na prave lokacije, u pravo vrijeme,

s ciljem

minimiziranja ukupnih troškova i maksimiziranjem razine usluge prema kupcu.

1.4. SCOR model

I kako krenuti s implementacijom koncepta lanca opskrbe? Prvi je korak popisati i vizualizirati sve procese, tijekove i odnose u lancu, te konstruirati koncepcijski model koji se naziva SCOR model (Supply Chain Operations Reference model). Opći okvir tog modela izgleda ovako:

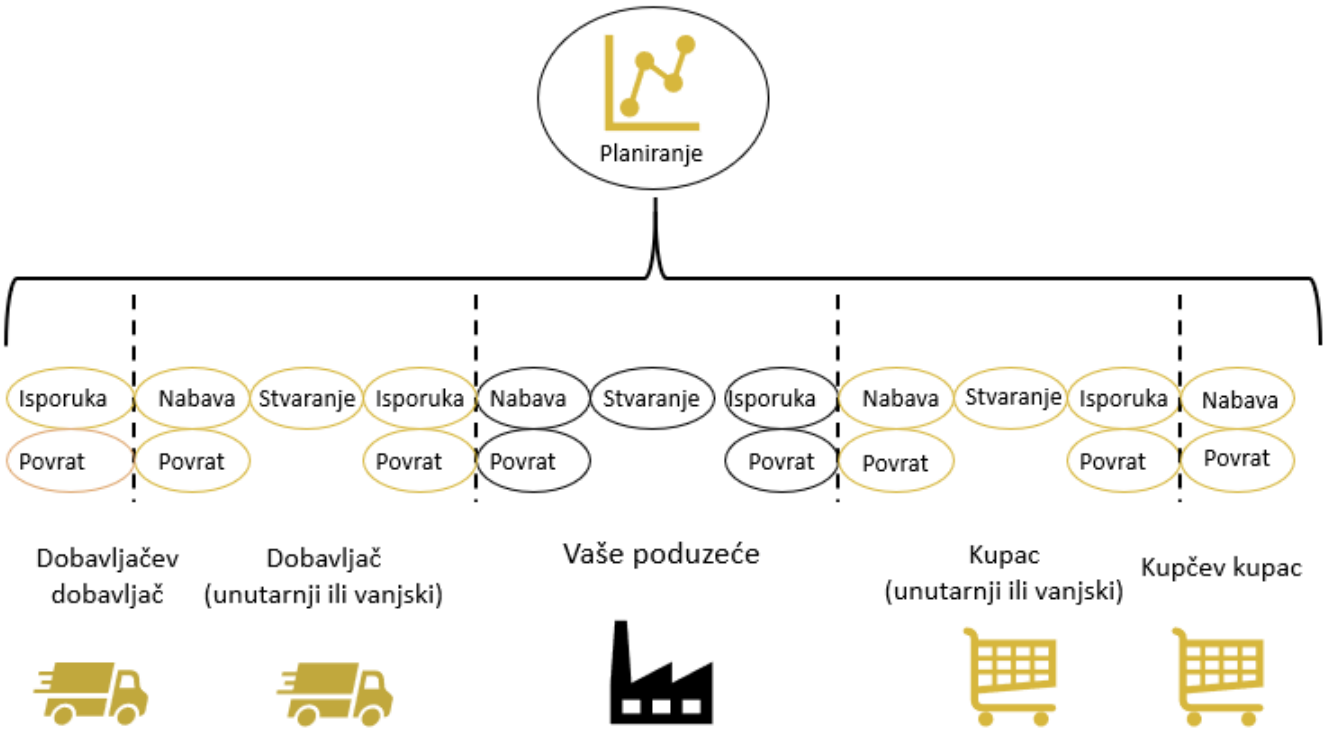

Kad se strategiji lanca opskrbe dodaju dizajn novog proizvoda, marketing i određivanja cijena, te financije, računovodstvo, IT, ljudski resursi, dolazimo do **vrijednosnog lanca**.

1.5. S&OP

Pored strukture, važni su i ljudi, te njihova suradnja, komunikacija, koordinacija, međusobno povjerenje i poštovanje. To se ostvaruje kroz koncept S&OP (Sales and Operations Planning), seriju redovnih krosfunkcionalnih sastanaka. Cilj je dogovor među različitim odjelima u svrhu uravnoteženja ponude i potražnje. Na temelju potražnje, kreiraju se planovi uzimajući u obzir ograničenja na resurse, te se upozorava kad resursi nisu u skladu s očekivanjima. Rezultat procesa S&OP je agregatni plan.

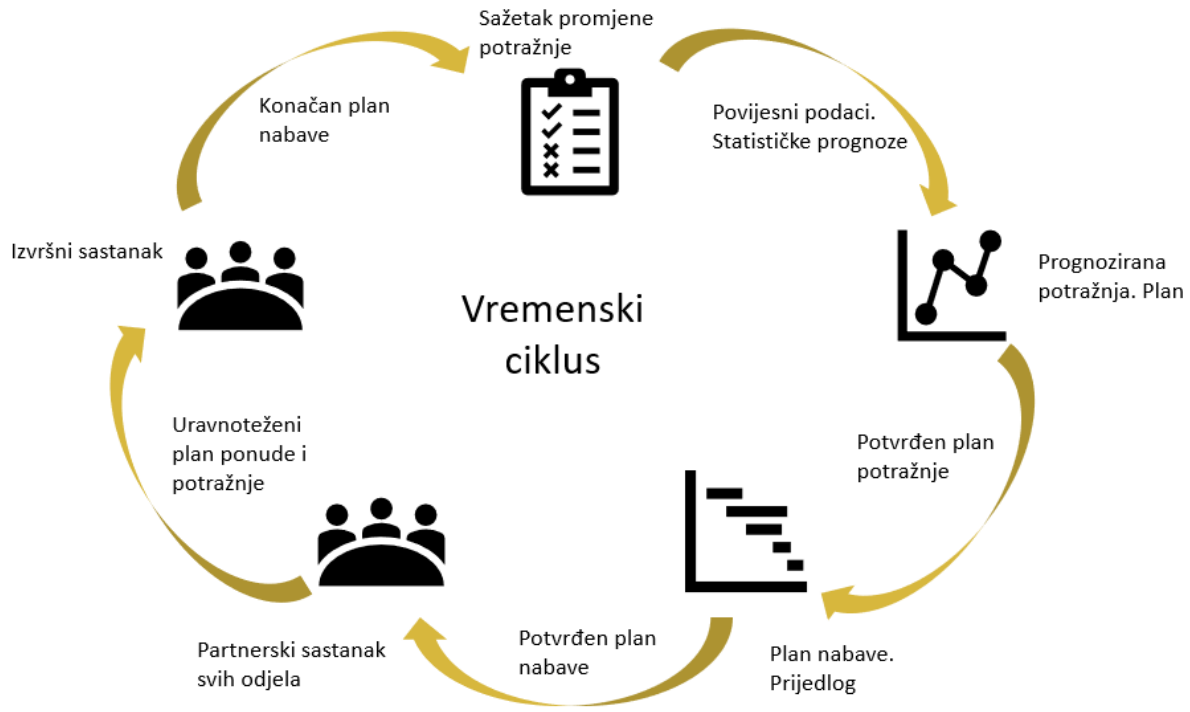

1.6. Analitičke metode za upravljanje lancem opskrbe

Pored strukture i ljudi, važna je i optimizacija. Da bismo imali dobru optimizaciju, potrebna nam je IT infrastruktura, te odgovarajuće analitičke metode i alati. U svakoj točki lanca opskrbe potrebno je izvršiti određenu optimizaciju. Na sljedećoj je slici dan prikaz metoda koja se koriste u određenoj točki lanca.

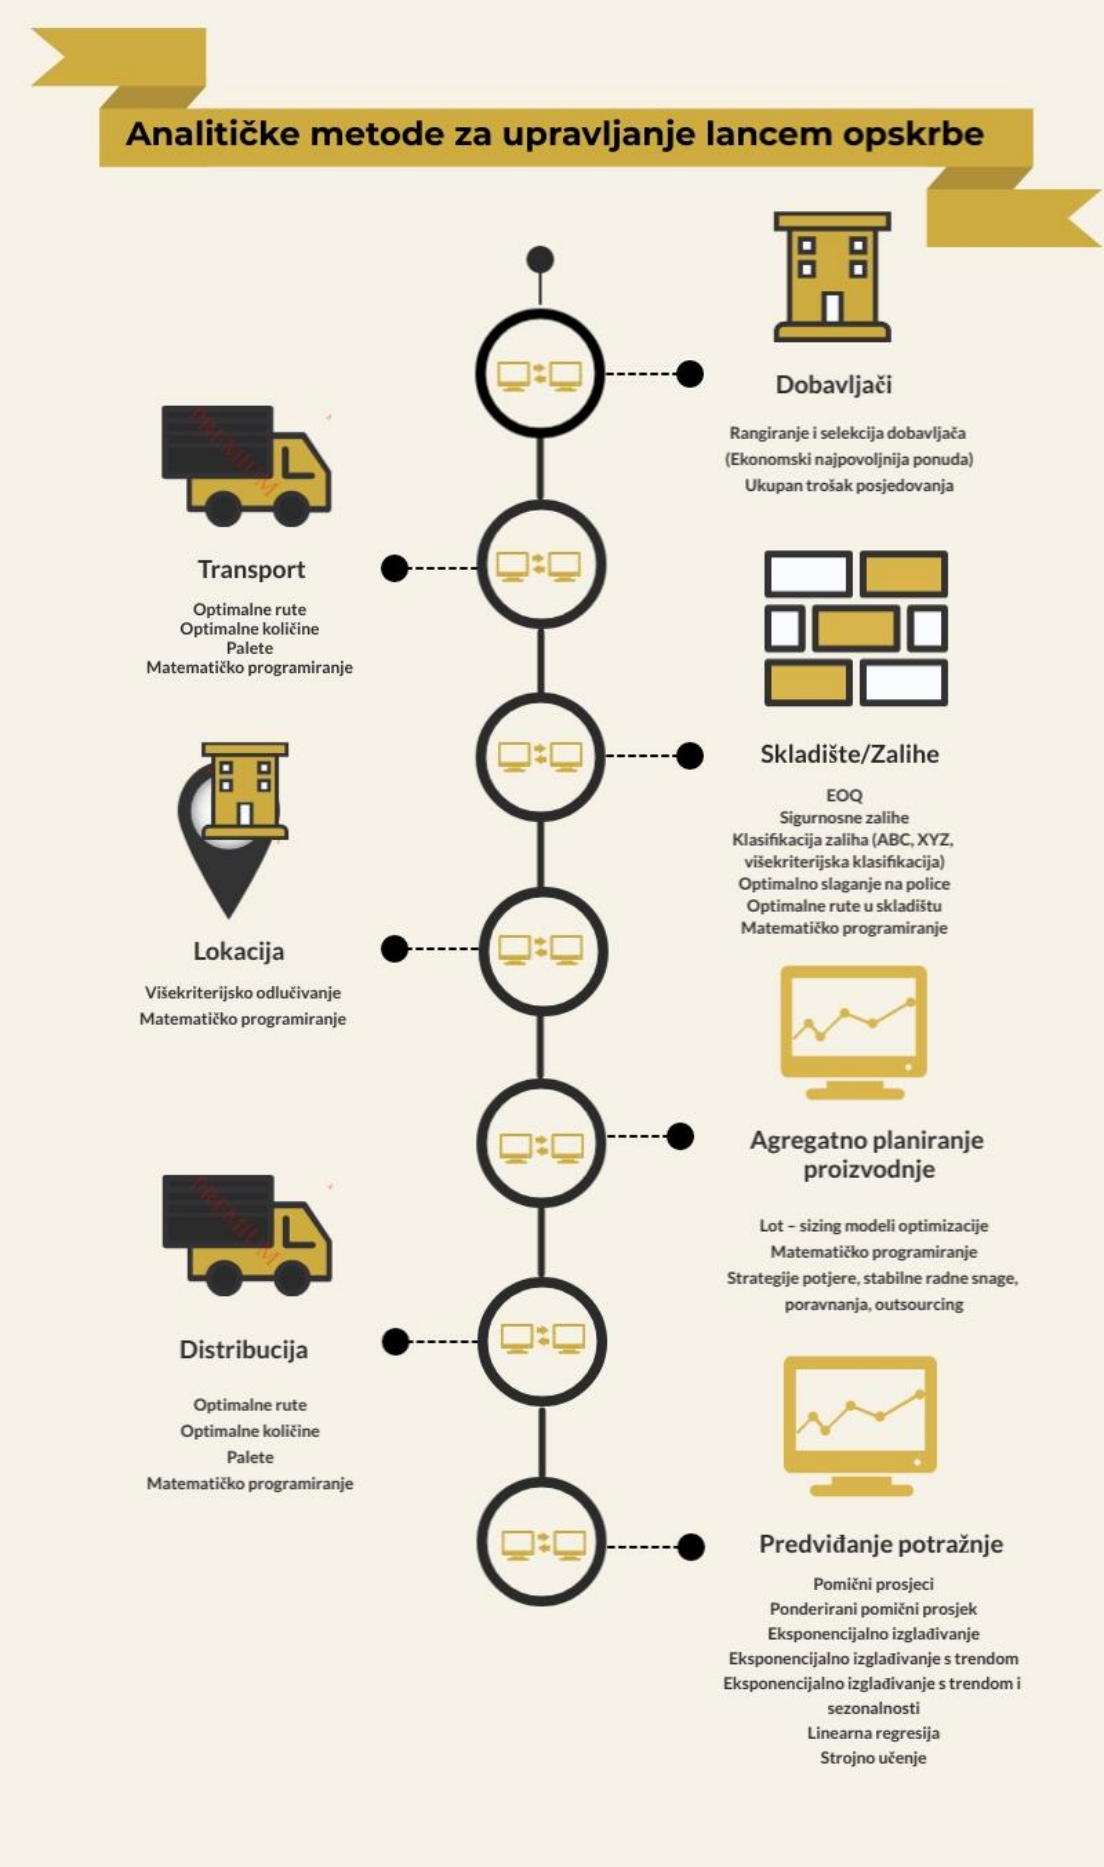
Analitičke metode za upravljanje lancem opskrbe
Dobavljači
Rangiranje i selekcija dobavljača
(Ekonomski najpovoljnija ponuda)
Ukupan trošak posjedovanja
Transport
Optimalne rute
Optimalne količine
Palete
Matematičko programiranje
Skladište/Zalihe
EOQ
Sigurnosne zalihe
Klasifikacija zaliha (ABC, XYZ, višekriterijska klasifikacija)
Optimalno slaganje na police
Optimalne rute u skladištu
Matematičko programiranje
Lokacija
Višekriterijsko odlučivanje
Matematičko programiranje
Agregatno planiranje proizvodnje
Lot – sizing modeli optimizacije
Matematičko programiranje
Strategije potjere, stabilne radne snage, poravnanja, outsourcing
Distribucija
Optimalne rute
Optimalne količine
Palete
Matematičko programiranje
Predviđanje potražnje
Pomični prosjeci
Ponderirani pomični prosjek
Eksponencijalno izglađivanje
Eksponencijalno izglađivanje s trendom
Eksponencijalno izglađivanje s trendom i sezonalnosti
Linearna regresija
Strojno učenje

2. Mreža lanca opskrbe (Distribucija i lokacija)

Distribucija se odnosi na korake koji se poduzimaju da bi se **roba kretala i skladištila** na svom putu od dobavljača prema potrošaču u lancu opskrbe.

Upravljanje distribucijom uključuje:

- Skladištenje
- Rukovanje materijalima
- Pakiranje
- Upravljanje zalihama
- Upravljanje narudžbama
- Transport

Distribucija se događa između svake dvije faze u lancu opskrbe.

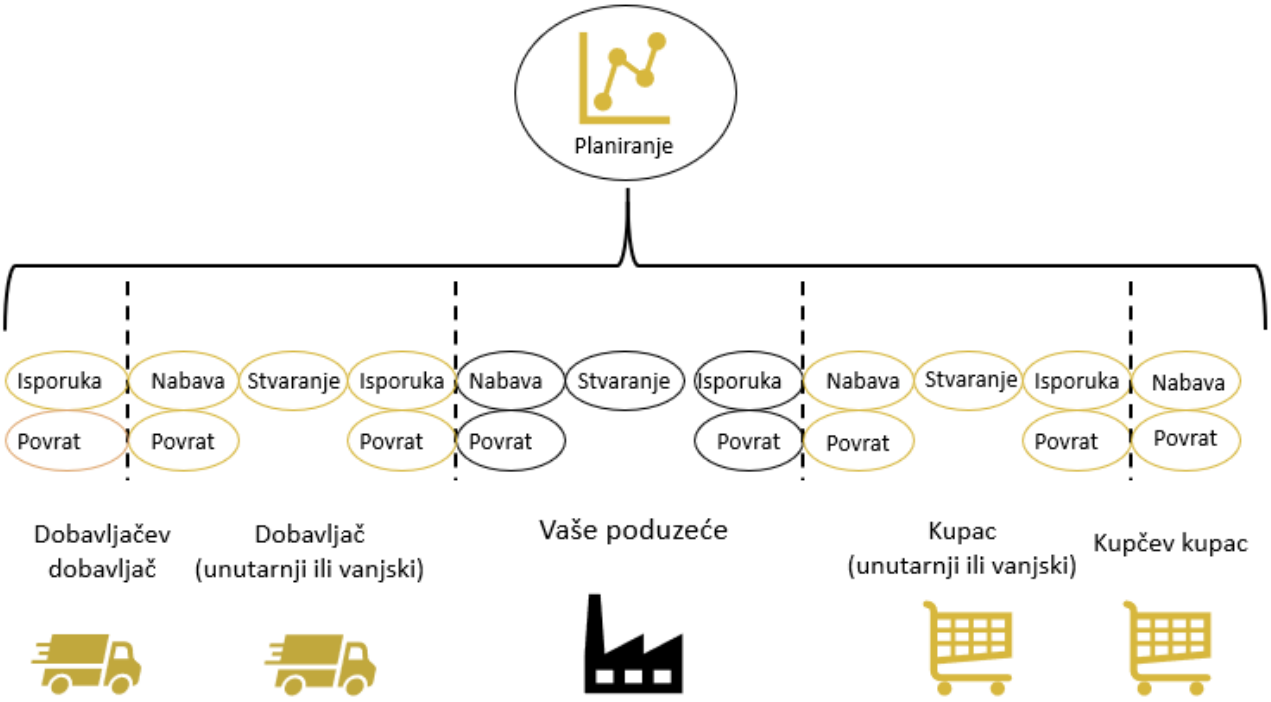

Na najvišoj razini, izvedba distributivne mreže može se ocijeniti kroz dvije dimenzije:

- Zadovoljavanje potreba kupaca - efektivnost
- Trošak zadovoljavanja potreba kupaca – efikasnost

Kako kreirati dobru distributivnu mrežu u svrhu balansiranja između efikasnosti i efektivnosti?

2.1. Strategije kreiranja mreže u lancu opskrbe

Efektivnost. Kod potrošača, struktura distributivne mreže utječe na:

- Vrijeme isporuke
- Raznolikost proizvoda
- Raspoloživost proizvoda
- Iskustvo potrošača (je li jednostavno naručiti robu ili nije?)
- Vrijeme plasiranja novog proizvoda na tržište
- Vidljivost narudžbe (praćenje proizvoda na putu do potrošača)
- Mogućnost povrata

Efikasnost. Distributivna mreža utječe na sljedeće troškove u lancu opskrbe:

- Zalihe
- Transport
- Objekti, upravljanje i održavanje
- Informacije

Postoje različite opcije dizajniranja distributivne mreže, ovisno o broju i položaju posrednika između proizvođača i potrošača:

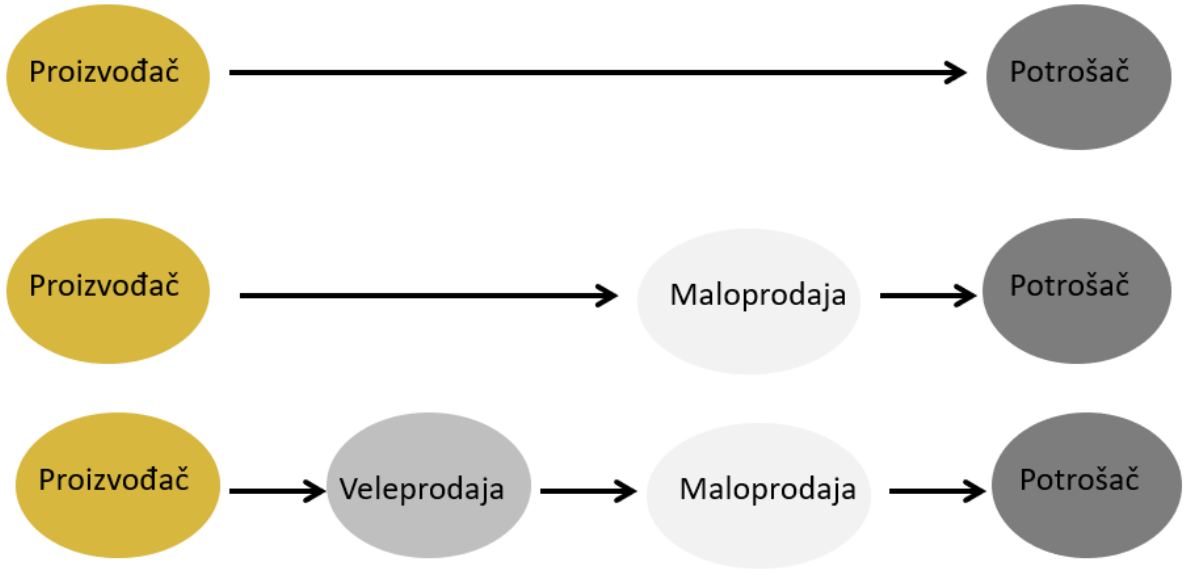

Posrednik smanjuje broj veza za komunikaciju u mreži, pa smo efikasniji. Ali, ne smijemo broj veza previše smanjiti jer nećemo biti efektivni. Također, kod predviđanja agregatne potražnje (na razini distributivnog centra), pogreška predviđanja je manja nego kod predviđanja pojedinačnih potražnji (na razini prodajnog mjesta). To je jedan od glavnih razloga zašto se mali igrači na tržištu trebaju udruživati. Na primjer, mali dućani s udruživanjem povećavaju

pregovaračku moć prema dobavljaču, a i smanjuju si troškove i pogrešku u predviđanju potražnje.

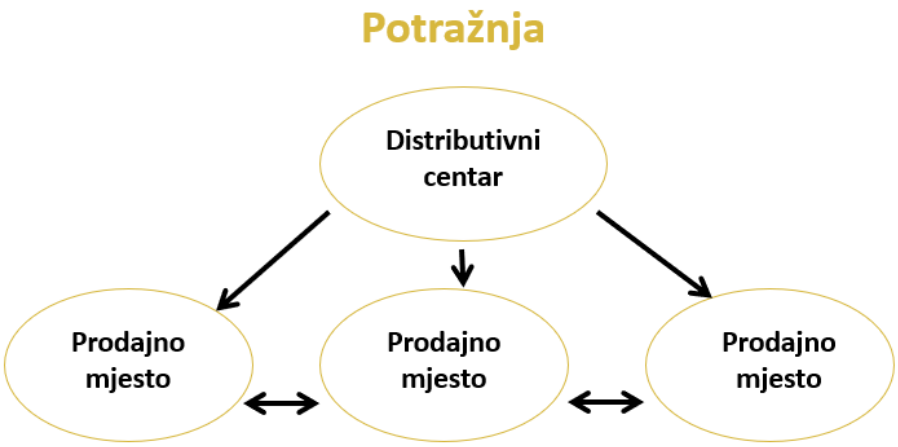

Neke varijante distributivne mreže dane su u daljnjem tekstu.

Varijanta 1 distributivne mreže. Proizvođači i potrošači su direktno povezani.

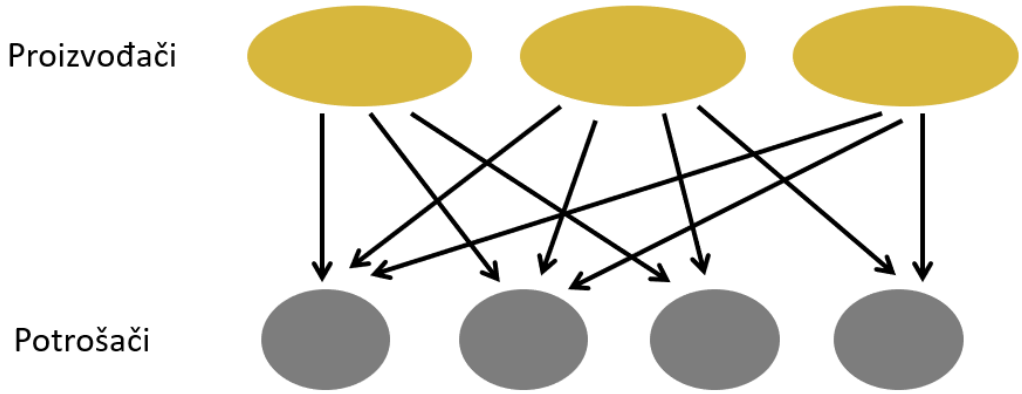

Karakteristike:

- Troškove zaliha snosi proizvođač
- Troškovi transporta visoki
- Dugo vrijeme odziva
- Iskustvo potrošača dobro jer je dostava na kućni prag
- Iskustvo potrošača loše zbog različitih proizvođača i parcijalnih pošiljki

Varijanta 2 distributivne mreže. Između proizvođača i potrošača postoje posrednici.

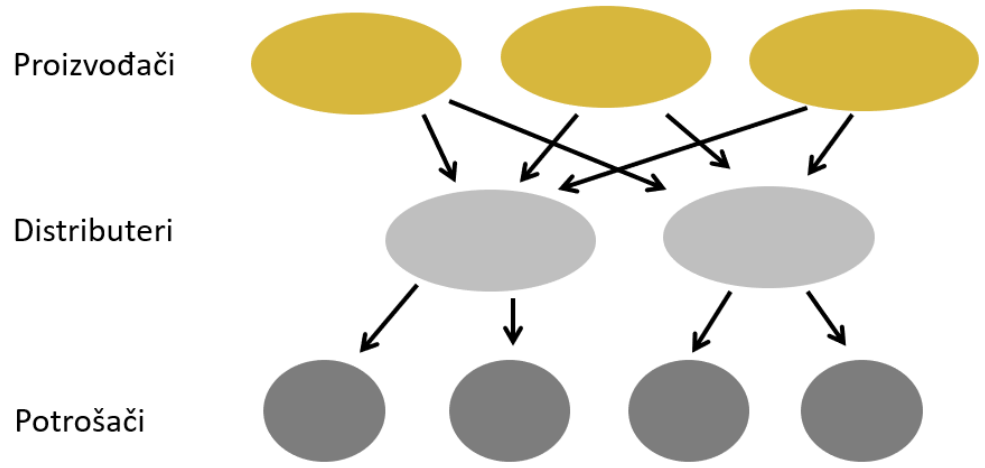

Karakteristike:

- Troškove zaliha snose proizvođač i distributer
- Troškovi transporta niži
- Iskustvo potrošača bolje jer se radi o jednoj pošiljci

Varijanta 3 distributivne mreže.

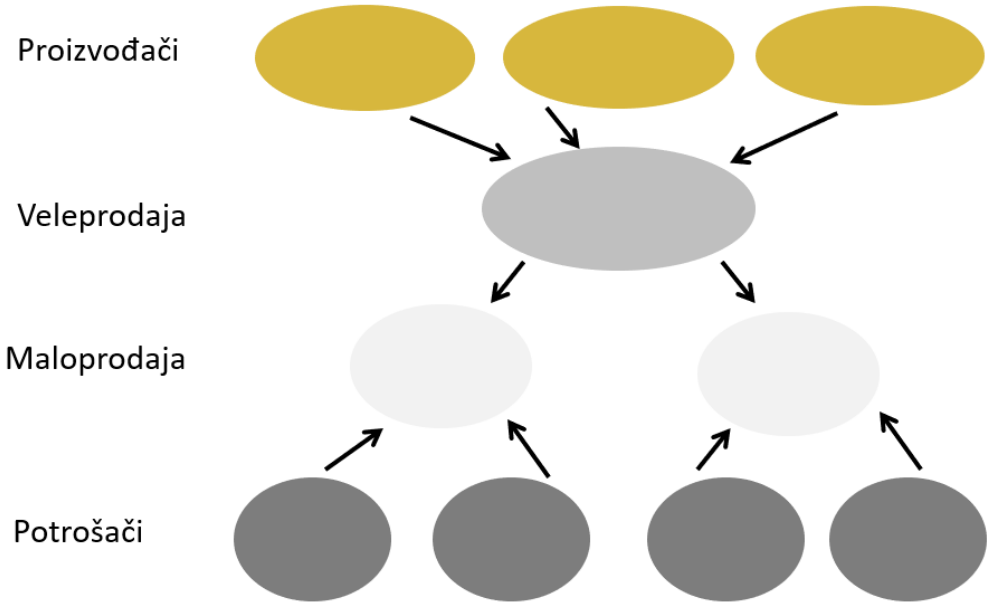

Karakteristike:

- Troškovi zaliha ovise o lokaciji
- Troškovi transporta su niži
- Vrijeme odziva brzo
- Iskustvo potrošača možda lošije jer nema dostave na kućni prag

Lokacija

Odluke u mreži lanca opskrbe se klasificiraju na sljedeći način:

- Uloga objekta (Koji procesi?)
- Lokacija objekta
- Alokacija kapaciteta
- Alokacija ponude i tržišta (Koja tržišta će određeni objekt opskrbljivati? Koji će dobavljači opskrbljivati koje objekte?)

Kad se donose odluke o dizajnu sljedeće bi informacije trebale biti dostupne:

- Lokacija dobavljača i tržišta
- Potencijalne lokacije objekata
- Prognoza potražnje na tržištu
- Troškovi objekta, radne snage i materijalni troškovi
- Transportni troškovi između svake dvije lokacije
- Fiksni i varijabilni troškovi zaliha po lokaciji
- Prodajna cijena proizvoda u različitim regijama
- Porezi i ostala davanja
- Poželjno vrijeme odziva i ostali elementi usluge

3. Upravljanje potražnjom

Lanac opskrbe smo definirali kao koordinirani sustav protoka materijala, usluga i informacija od dobavljača do kupca.

Preciznije, na tržištu se kreira potražnja, ta se informacija šalje lancu opskrbe koji se onda aktivira kako bi zadovoljio potražnju. I cijelo se vrijeme balansira na kontinuumu između efikasnosti i efektivnosti.

A da bismo bili efektivni koristimo i strategije upravljanja potražnjom. Pritom razlikujemo dvije vrste potražnje:

- **Nezavisna potražnja** – direktan rezultat stanja na tržištu
- **Zavisna potražnja** – dobiva se kalkulacijom iz nezavisne potražnje. Ovdje je potražnja za jednim proizvodom u direktnoj vezi s potražnjom za nekim drugim proizvodom

Dakle, potražnja za voćnim sokom je određena na tržištu. Na temelju te potražnje i sastavnice materijala, računaju se potražnje za voćem, vodom, etiketama i bocama.

Mi ćemo u ovom poglavlju obrađivati nezavisnu potražnju. Pritom se na tu potražnju može utjecati na više načina. Na primjer:

- Određivanje cijena (Pricing)
- Promocija
- Odgođena isporuka (Backorders)
- Stvaranje nove potražnje

Također, da bi se kreirao dobar agregatni plan, važno je što je više moguće točno prognozirati nezavisnu potražnju. Kod nezavisne potražnje provodimo predviđanje, a kod zavisne potražnje izračunavanje. Postoje različite metode prognoze koje koriste povijesne podatke o potražnji. Mi ćemo u ovom poglavlju obraditi neke od njih:

- Metoda pomičnog prosjeka
- Metoda ponderiranog pomičnog prosjeka
- Metoda eksponencijalnog izglađivanja
- Metoda eksponencijalnog izglađivanja s trendom
- Metoda eksponencijalnog izglađivanja s trendom i sezonalnosti – multiplikativni model
- Metoda eksponencijalnog izglađivanja s trendom i sezonalnosti – aditivni model
- Metoda eksponencijalnog izglađivanja s trendom i sezonalnosti – prošireni aditivni model

Pored ovih, u zadnje je vrijeme popularno rudarenje podataka, kao i strojno učenje. Naravno, odmah se nameće pitanje koja je metoda najbolja. Odgovor je da ni za jednu metodu ne možemo reći da je najbolja. Svaki skup podataka ima svoje specifičnosti. Također, kod svake se metode mogu mijenjati formule za inicijalizaciju i formule za predviđanje. Podatkovni analitičar vrši simulacije i traži metodu i formule koje najbolje opisuju ponašanje danog skupa podataka.

Također, možemo prognozirati **kratkoročno, srednjoročno i dugoročno**. Kratkoročno se obično odnosi na period ispod tri mjeseca, srednjoročno od tri do 18 mjeseci, a dugoročno se odnosi na period iznad 12 do 18 mjeseci. Ne postoji stroga granica, ali općenito, podjela je više manje ta.

Dobro upravljanje potražnjom je važno i da se izbjegne **efekt biča** u lancu opskrbe kada svaki član uzvodno uz lanac počinje naručivati sve više i više, a sve zbog neizvjesnosti u kretanju potražnje.

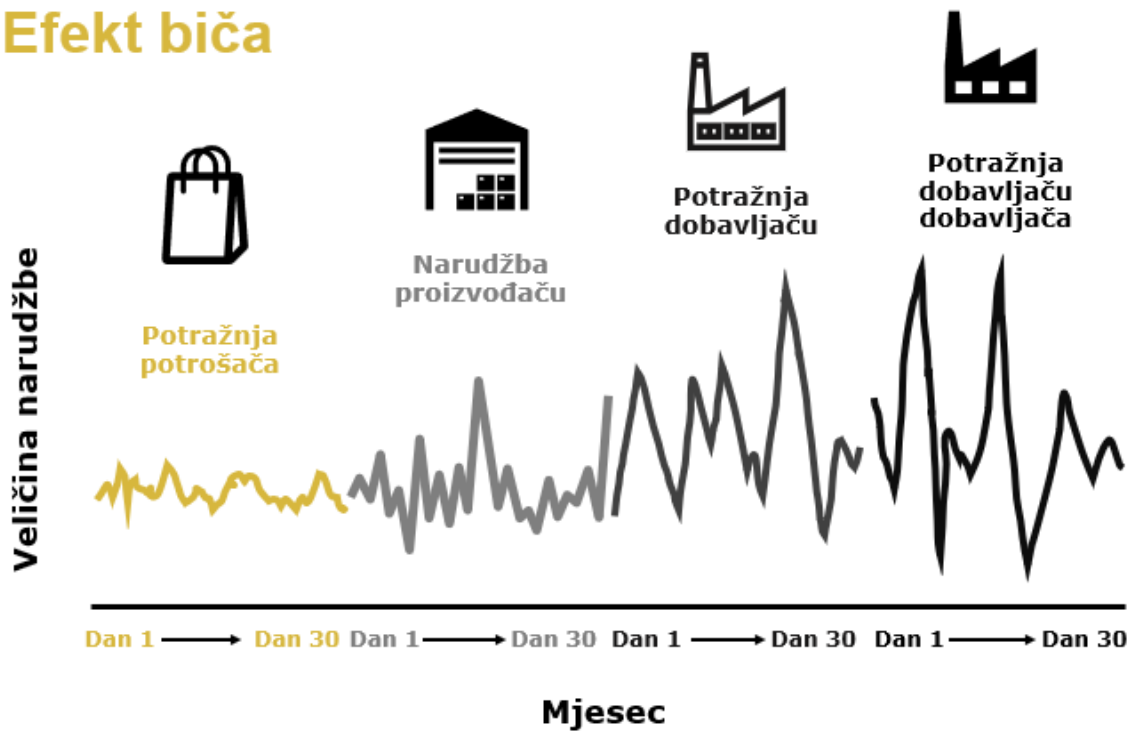

Prije nego što se primijeni neka od metoda prognoziranja, preporuča se vizualizirati podatke. Iz tih vizualizacija mogu se identificirati komponente potražnje kao što su:

- Prosjek
- Trend – sustavni porast ili pad u prosječnoj potražnji
- Sezonalnost – predviđeni pad ili porast u ovisnosti o periodu
- Ciklusi – poslovni ciklusi i životni ciklus proizvoda (makroekonomski utjecaj)
- Slučajna pogreška (uvijek postoji mogućnost)

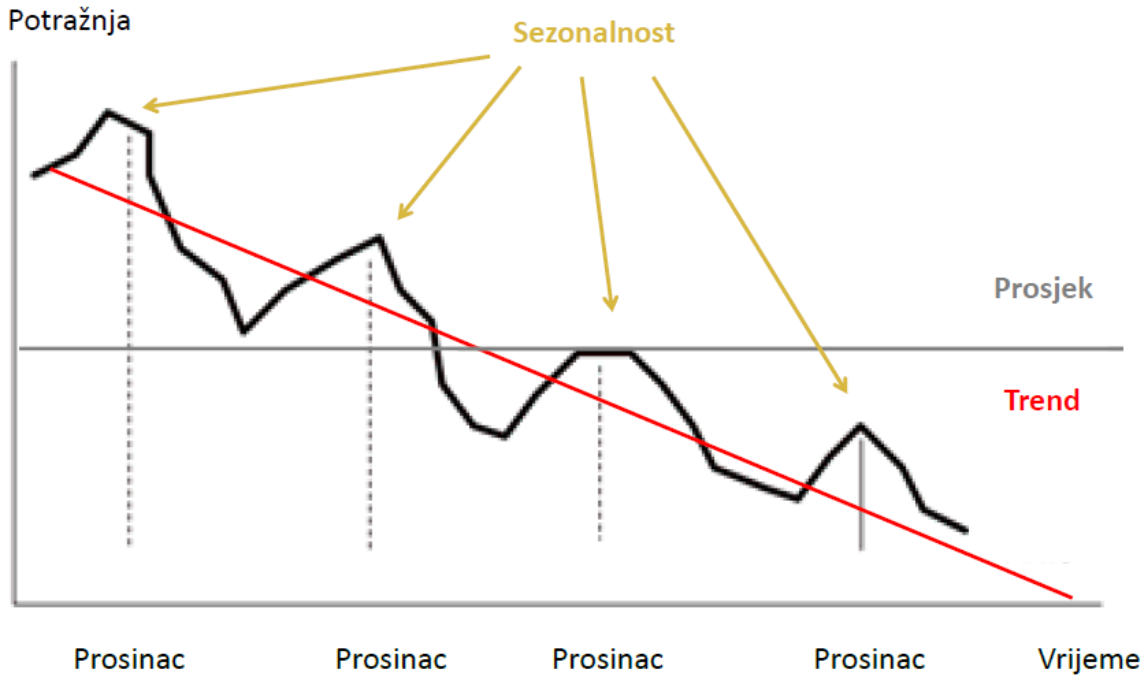

Sve u jednoj slici:

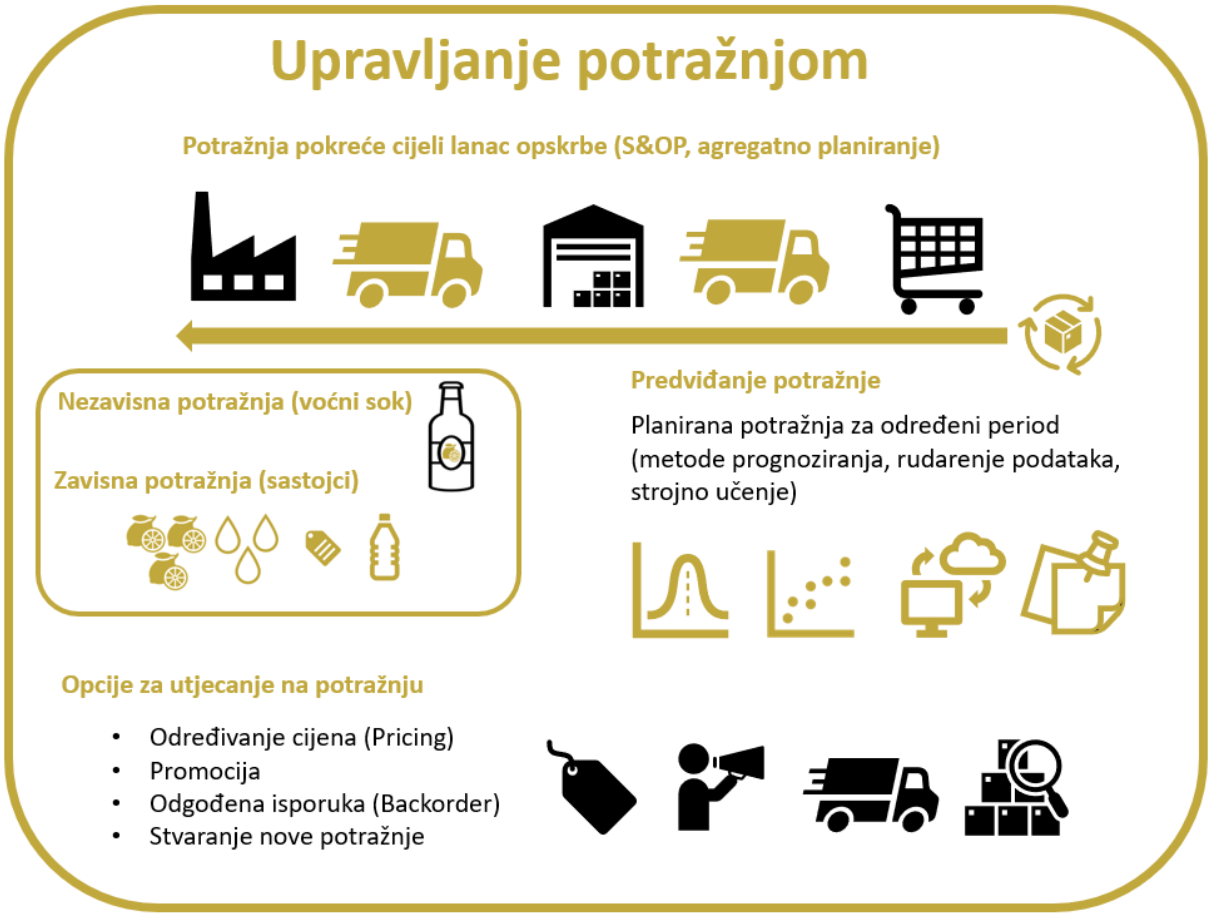

Primjer 1. Zadani su povijesni mjesečni podaci za kretanje potražnje:

Mjesec	Potražnja
1	800,00
2	1400,00
3	1000,00
4	1500,00
5	1500,00
6	1300,00
7	1800,00
8	1700,00
9	1300,00
10	1700,00
11	1700,00
12	1500,00
13	2300,00
14	2300,00
15	2000,00
16	1700,00
17	1800,00
18	2200,00
19	1900,00
20	2400,00
21	2400,00
22	2600,00
23	2000,00
24	2500,00
25	2600,00
26	2200,00
27	2200,00
28	2500,00
29	2400,00
30	2100,00

Vizualizirajte podatke i komentirajte.

Rješenje.

Za vizualizaciju podataka možemo koristiti Excel. Na primjer, graf raspršivanja i linijski graf.

Graf raspršivanja:

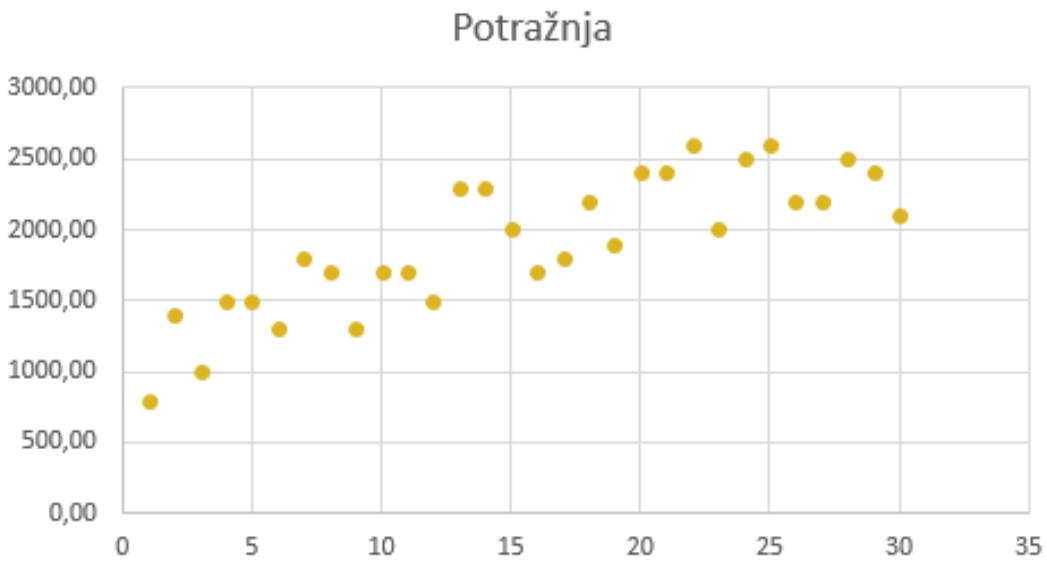

Linijski graf:

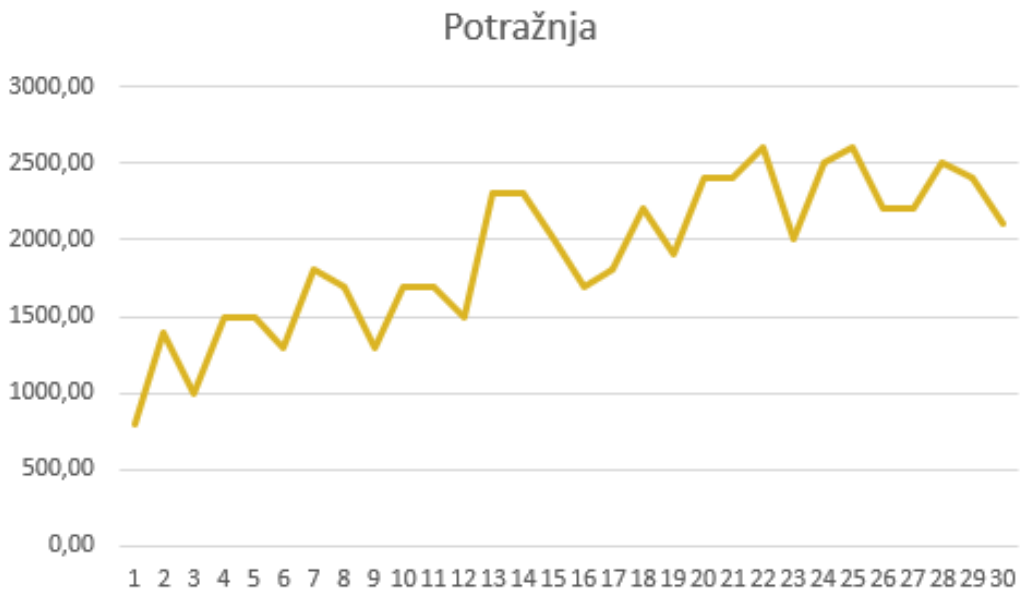

Iz vizualizacije podataka, tj., grafova, možemo uočiti pozitivan trend. Budući da postoji trend, metoda pomičnih prosjeka neće biti prikladna metoda, ali ipak ćemo je primijeniti da vidimo kako se ponaša. Također, primjećujemo oscilacije, tj., mjesečne cikluse.

Kako metode prognoziranja funkcioniraju? Skup povijesnih podataka podijelimo na dva podskupa. Prvi podskup nam služi da bismo učili (trenirali), a drugi da bismo testirali (validirali). Ne postoji neko pravilo kako podijeliti skup podataka na ova dva podskupa.

Kod učenja, na temelju povijesnih podataka iz odgovarajućeg skupa, pretpostavimo da smo prognoziranje provodili kroz tu istu povijest. Dakle, za svaki period u povijesti izračunamo prognoziranu vrijednost kao da smo tada prognozirali. Parametri modela se određuju pomoću skupa za učenje, dok se kvaliteta modela određuje na temelju skupa za testiranje. Na temelju stvarne (aktualne) vrijednosti i prognozirane vrijednosti u prošlosti računamo pogreške. Najbolja metoda je ona koja ima najmanju pogrešku odstupanja prognozirane od stvarne vrijednosti.

Napomena. Ovdje valja napomenuti da mi nećemo skup povijesnih podataka dijeliti na spomenuta dva podskupa. Mi ćemo promatrati jedan skup podataka na kojem ćemo izračunati i parametre modele i odgovarajuću pogrešku.

Prije samih metoda, dat ćemo pregled mjera pogrešaka. U tu svrhu uvodimo oznake:

n – broj podataka

A_t – aktualna (stvarna) potražnja za period t

F_t – prognozirana potražnja za period t

Neke od mjera koje se koriste za računanje pogrešaka su sljedeće:

Srednje apsolutno odstupanje (Mean absolute deviation - MAD)

$$MAD = \frac{\sum_{t=1}^{n} |A_t - F_t|}{n}$$

Srednja apsolutna pogreška u postocima (Mean absolute percent error - MAPE)

$$MAPE = \frac{MAD}{Prosječna\ potražnja}$$

Srednje kvadratno odstupanje (Mean Squared Error - MSE)

$$MSE = \frac{\sum_{t=1}^{n}(A_t - F_t)^2}{n}$$

Srednja apsolutna pogreška u postocima (Mean absolute percent error) – **varijanta**

$$MAPE = \frac{\sum_{t=1}^{n} 100|A_t - F_t|/A_t}{n}$$

4. Upravljanje zalihama

4.1. Uvod

Što su zalihe? Koja im je svrha? Što znači upravljati zalihama? Na koliko se razina lanca opskrbe drže zalihe? Koje vrsta zaliha postoje?

Jedna od definicija zalihe je i ta da je zaliha količina stavki na skladištu koja podržava proizvodnju i traženu razinu usluge prema kupcu. Upravljati zalihama znači odgovoriti na sljedeća pitanja:

- Koliko često treba provjeravati zalihe i plasirati narudžbu?
- Koliko treba naručiti?
- Na kojoj razini zaliha treba plasirati narudžbu?
- Kako upravljati zalihama uz zahtijevanu razinu usluge prema potrošačima? Kako definirati razinu usluge prema potrošačima?
- Treba li voditi računa o svim proizvodima na zalihama ili samo nekima?

Kako povećavati efikasnost upravljanjem zalihama i istovremeno doprinijeti povećanju efektivnosti? To je vječiti trade – off.

Zalihe u lancu opskrbe postoje kako bi se uravnotežile ponuda i potražnja. Ukoliko je strategija poduzeća efektivnost, zalihe će se držati na razini gotovih proizvoda, bliže kupcu. Ukoliko je strategija poduzeća efikasnost, zalihe će se držati na razini sirovina ili centralnog skladišta. Efektivnost rezultira u visokim, a efikasnost u niskim zalihama. Također, možemo reći da je svrha zaliha i sljedeće:

- Zadovoljavanje varijabilne potražnje
- Dozvoljavanje fleksibilnosti u proizvodnji (kad je stroj jednom postavljen na jedan proizvod, isplati se proizvesti veća količina)
- Zaštita od nepouzdanosti dobavljača
- Iskorištavanje prednosti naručivanja većih količina (popust na količinu)

S druge strane, zalihe skrivaju probleme (loše prognoze potražnje, loši odnosi s dobavljačem, uska grla, nepouzdani dobavljači i slično). Smanjivati zalihe, a ne rješavati probleme može biti pogubno.

Jednorazinski lanac opskrbe karakterizira distributivna poduzeća i to ona koja zalihe zaprimaju, čuvaju i izdaju na jednom mjestu. Proizvodna poduzeća imaju najmanje **dvije razine** lanca opskrbe. Zalihe se mogu držati na svim razinama i pritom je važna integracija, koordinacija i suradnja u lancu.

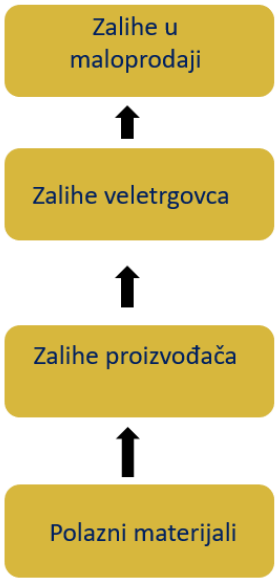

Vrste zaliha s obzirom na razlog postojanja:

- **Cikličke zalihe** – poduzeće nabavlja i proizvodi u ciklusima između dvije isporuke (uglavnom stabilna potražnja)
- **Sigurnosne zalihe** – zaštita od rizika (tj., neizvjesnosti u potražnji, zastoja u proizvodnji, problema u kvaliteti proizvoda, kašnjenja polaznih materijala i slično)
- **Prekomjerne zalihe** (špekulativne zalihe)
- **Sezonska zaliha**

- **Promocijska zaliha**
- **Nekurentna zaliha** (zastarjeli proizvodi koji se više ne mogu prodati)

4.2. Cikličke zalihe

Cikličke zalihe se pojavljuju jer poduzeće nabavlja materijal/robu/proizvode u *batchevima* u regularnim vremenskim periodima. Na primjer, poduzeće prodaje 5 komada određenog proizvoda dnevno, a naručuje po 50 komada tog istog proizvoda. Dakle, u prosjeku će poduzeće prodati svih 50 komada u roku od deset dana, pa je ciklus jednak deset dana. Pritom pretpostavljamo da je potražnja stabilna (konstantna). Grafički, za horizont od 30 dana, to izgleda ovako:

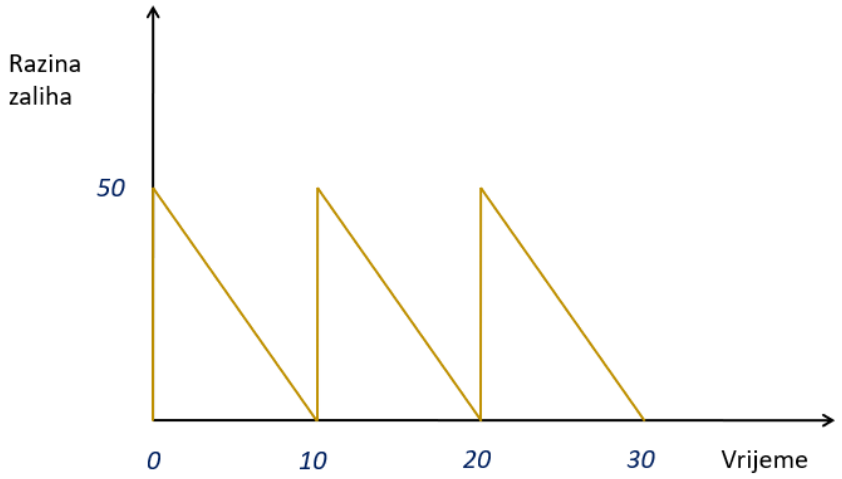

No, poduzeće može naručivati i po 25 komada tog proizvoda. Dakle, u prosjeku će poduzeće prodati svih 25 komada u roku od pet dana, pa je ciklus jednak pet dana. Grafički, to izgleda ovako:

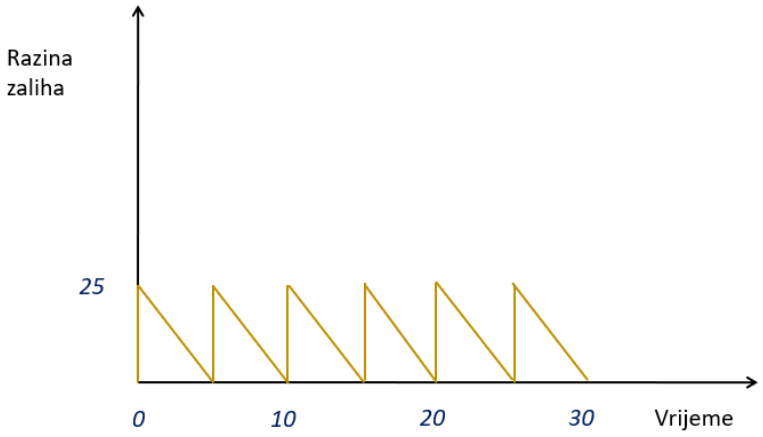

Postavlja se pitanje, naručivati rijetko veće količine ili često manje količine? To je trade-off koji postoji u ovom slučaju. Uzmemo li u obzir trošak narudžbe i trošak držanja zaliha, odgovor na ovo pitanje ovisi o njihovim vrijednostima.

Uvedimo oznake za neki promatrani period:

- Q – količina narudžbe *(batch)*
- D – potražnja za proizvodom u tom periodu
- S – fiksni trošak jedne narudžbe
- C – jedinični trošak (cijena) proizvoda
- h – jedinični trošak držanja zaliha kao postotak jedinične cijene u tom periodu

Dakle, jedinični trošak držanja zaliha je dan kao $H = hC$. Nabava donosi odluku na temelju ovih troškova za promatrani period:

- Trošak materijala
- Trošak narudžbe
- Trošak držanja zaliha

Trošak materijala je CD.

Broj narudžbi je $\frac{D}{Q}$, pa je trošak narudžbi jednak $S\frac{D}{Q}$.

Prosječna je zaliha jednaka $\frac{Q}{2}$, pa je trošak držanja zaliha $H\frac{Q}{2}$.

Ukupan je trošak jednak zbroju ta tri troška, tj.,

$$CD + S\frac{D}{Q} + H\frac{Q}{2}.$$

Napomena. Formula je izvedena uz pretpostavku vrijednosti za neki promatrani period. Treba voditi računa da su potražnja i trošak držanja zaliha dani za isti taj period. Na primjer, ako je zadana godišnja potražnja onda je trošak držanja zaliha dan na godišnjoj razini. Ako je zadana potražnja za 30 dana onda i trošak držanja zaliha mora biti zadan na razini 30 dana.

Pretpostavimo li da je za period od 30 dana $C = 10,\ S = 8,\ h = 0{,}2$, slijedi da je $H = 0{,}2 \cdot 10 = 2$, te

- Slučaj 1. $Q = 50$, a ukupni trošak $10 \cdot 150 + 8 \cdot \frac{150}{50} + 2 \cdot \frac{50}{2} = 1500 + 24 + 50 = 1574$
- Slučaj 2. $Q = 25$, a ukupni trošak $10 \cdot 150 + 8 \cdot \frac{150}{25} + 2 \cdot \frac{25}{2} = 1500 + 48 + 25 = 1573$

Vidimo da je trošak materijala CD isti u oba slučaja, pa da bismo minimizirali ukupan trošak, dovoljno je minimizirati zbroj troška narudžbe i troška držanja zaliha. Tj., cilj nam je pronaći količinu Q koja minimizira taj zbroj:

$$\min_Q \left(S\frac{D}{Q} + H\frac{Q}{2} \right)$$

Simulacije za različite količine narudžbe pokazuju sljedeće:

Naručena količina Q	Trošak narudžbi $S\frac{D}{Q}$	Trošak držanja zaliha $H\frac{Q}{2}$	Ukupan trošak 1500+ $S\frac{D}{Q} + H\frac{Q}{2}$
10	120,00	10	1630,00
15	80,00	15	1595,00
20	60,00	20	1580,00
25	48,00	25	1573,00
30	40,00	30	1570,00
35	34,29	35	1569,29
40	30,00	40	1570,00
45	26,67	45	1571,67
50	24,00	50	1574,00
55	21,82	55	1576,82
60	20,00	60	1580,00
65	18,46	65	1583,46
70	17,14	70	1587,14

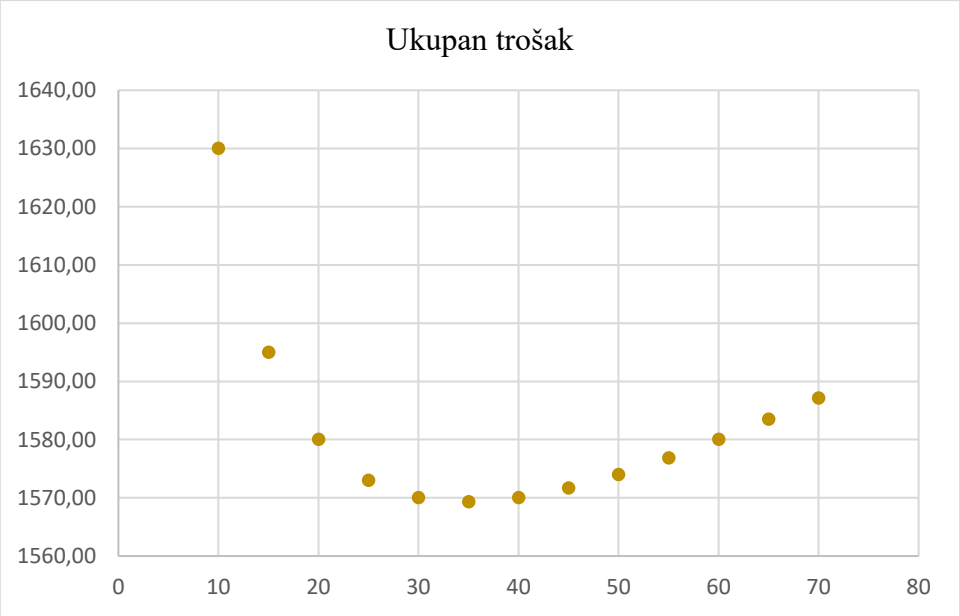

Vidimo da je količina koja minimizira ukupne troškove negdje u intervalu između 30 i 40, tj., oko 35. Njezinu točnu vrijednost dobit ćemo iz uvjeta prvog reda koji derivaciju funkcije izjednačava s nulom, tj.,

$$-S\frac{D}{Q^2}+\frac{H}{2}=0$$

Rješenje ove jednadžbe je $Q=\sqrt{\frac{2DS}{H}}$ i naziva se **ekonomska količina narudžbe** (*EOQ – Economic Order Quantity)*. Dakle,

$$EOQ=\sqrt{\frac{2DS}{H}}$$

Za gornji primjer, $EOQ=\sqrt{\frac{2\cdot 150\cdot 8}{2}}=\sqrt{150\cdot 8}=\sqrt{1200}=34{,}64$. Ukupan je trošak tada jednak zbroju troška materijala, troška narudžbi i troška držanja zaliha:

$$10\cdot 150+8\cdot\frac{150}{34{,}64}+2\cdot\frac{34{,}64}{2}=1500+8\cdot 4{,}33+34{,}64$$

$$=1500+34{,}64+34{,}64=1569{,}28$$

Napomena. Za *EOQ*, trošak narudžbi je uvijek jednak trošku držanja zaliha.

Također, optimalan broj narudžbi u promatranom periodu od 30 dana je $\frac{150}{34{,}64}=4{,}33$, tj., otprilike 4. Broj dana između dvije narudžbe je $\frac{30}{4{,}33}=6{,}93$, tj., otprilike 7 dana. Prosječan broj dana koje proizvod provede u sustavu je $\frac{0+6{,}93}{2}=3{,}465$.

4.3. Sigurnosne zalihe

Sigurnosne zalihe su zaštita od neizvjesnosti. U prvom redu, sigurnosne zalihe služe za zadovoljavanje neizvjesne potražnje i osiguranje od nedostatka proizvoda kad potražnja pređe prognoziranu vrijednost za određeni period. Neizvjesnost postoji i kod dobavljača, tj., u vremenu isporuke. Neizvjesnost postoji i u procesu proizvodnje, hoće li doći do prekida ili neće.

U ovom ćemo poglavlju dati formule za izračunavanje sigurnosnih zaliha uzimajući u obzir neizvjesnost u potražnji i vremenu isporuke. Pretpostavit ćemo da su te dvije varijable slučajne, normalno distribuirane varijable sa svojim srednjim vrijednostima, varijancama i standardnim devijacijama. Za izračun svih tih elemenata koristit ćemo Excel.

Napomena. Zamjerka pretpostavci normalne distribucije je da i negativne vrijednosti (potražnje i vremena isporuke) imaju određenu vjerojatnost, ali u praksi ta je vjerojatnost mala, pa je model ignorira.

Također, i dalje ćemo naručivati *EOQ*, ali će nam se promijeniti točka ponovne narudžbe čija će se vrijednost povećati za sigurnosne zalihe.

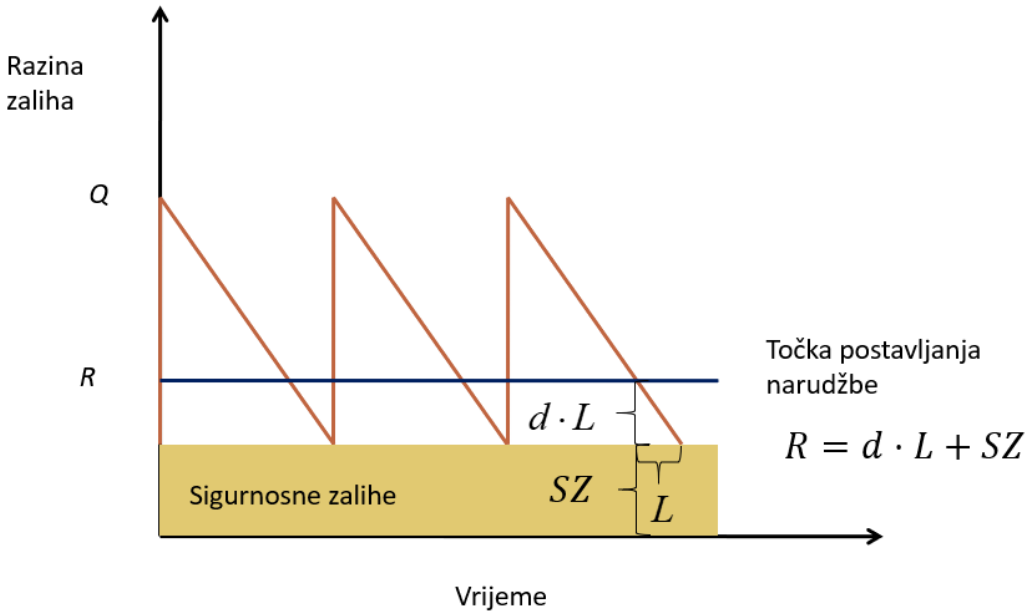

U modelima koji slijede, razina usluge prema kupcu se mjeri postotkom zadovoljene potražnje. Na primjer, ukoliko je razina usluge prema kupcu 95% (ili 0,95), znači da je poduzeće sposobno promptno zadovoljiti 95% potražnje direktno sa zaliha.

4.3.1. Varijabilna potražnja, konstantno vrijeme isporuke

Formula po kojoj računamo sigurnosne zalihe u slučaju varijabilne potražnje i konstantnog vremena isporuke je tzv. **formula drugog korijena**:

$$SZ = z \cdot \sigma \cdot \sqrt{L}$$

gdje su:

- L – vrijeme isporuke
- *z vrijednost* - broj standardnih devijacija za vjerojatnost željene razine usluge
- σ - standardna devijacija potražnje za jedan period

Na primjer, *z vrijednost* za razinu usluge prema kupcu od 95% je 1,644854. To možemo izračunati u Excelu kao =NORM.S.INV(0,95).

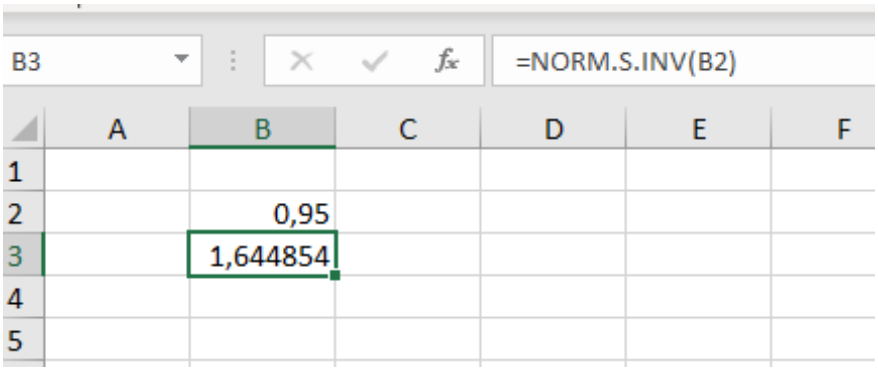

Neke *z vrijednosti:*

Razina usluge	z vrijednost
0,50	0,000000
0,55	0,125661
0,60	0,253347
0,65	0,385320
0,70	0,524401
0,75	0,674490
0,80	0,841621
0,85	1,036433
0,90	1,281552
0,95	1,644854
0,96	1,750686
0,97	1,880794
0,98	2,053749
0,99	2,326348
0,999	3,090232

Primjer 1. Izračunajte sigurnosne zalihe i točku postavljanja narudžbe ako je razina usluge prema kupcu 95%, vrijeme isporuke 2 dana, a povijesni podaci (prognoze) o dnevnim potražnjama su:

100
105
98
102
95
98
100
104
98

Rješenje.

Točka postavljanja narudžbe je $R = d \cdot L + SZ$.

	A	B	C	D	E
1					
2		Potražnje			
3		100		Prosjek	=AVERAGE(B3:B11)
4		105			
5		98		Standardna devijacija	=STDEV(B3:B11)
6		102			
7		95		Razina usluge	0,95
8		98			
9		100		z vrijednost	=NORM.S.INV(E7)
10		104		Vrijeme isporuke	2
11		98		**Sigurnosne zalihe**	=E9*E5*SQRT(E10)
12					
13				**Točka postavljanja narudžbe**	=E3*E10+E11
14					

	A	B	C	D	E
1					
2		Potražnje			
3		100		Prosjek	100,00
4		105			
5		98		Standardna devijacija	3,20
6		102			
7		95		Razina usluge	0,95
8		98			
9		100		z vrijednost	1,644854
10		104		Vrijeme isporuke	2
11		98		**Sigurnosne zalihe**	7,4474
12					
13				**Točka postavljanja narudžbe**	207,4474
14					

Mijenjamo li razinu usluge prema kupcu, uz konstantno vrijeme isporuke (2 dana), dobivamo drugačije vrijednosti sigurnosnih zaliha:

Razina usluge	z vrijednost	Sigurnosne zalihe
0,95	1,6449	7,4474
0,90	1,2816	5,8025
0,85	1,0364	4,6927
0,80	0,8416	3,8106
0,75	0,6745	3,0539
0,70	0,5244	2,3743
0,65	0,3853	1,7446
0,60	0,2533	1,1471

S porastom razine usluge prema kupcu, rastu i sigurnosne zalihe.

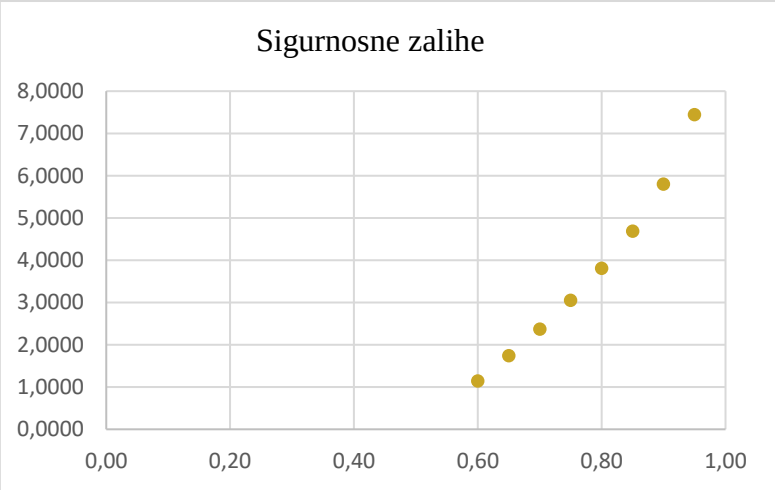

Nadalje, mijenjamo li vrijeme isporuke, uz konstantnu razinu usluge prema kupcu (95%), dobivamo drugačije vrijednosti sigurnosnih zaliha:

Vrijeme isporuke	Sigurnosne zalihe
1	5,2661
2	7,4474
3	9,1212
4	10,5322
5	11,7754
6	12,8993
7	13,9328

S porastom vremena isporuke, rastu i sigurnosne zalihe.

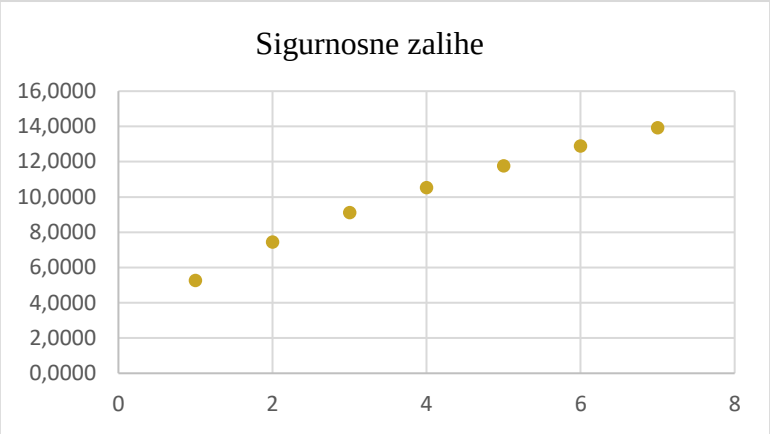

4.3.2. Varijabilna potražnja, varijabilno vrijeme isporuke

U slučaju da su i potražnja i vrijeme isporuke varijabilni, sigurnosne se zalihe računaju po formuli:

$$SZ = z \cdot \sqrt{\sigma_d^2 \cdot \overline{L} + d^2\sigma_L^2}$$

gdje su:

- σ_d^2 – varijanca potražnje
- $\overline{L}$ – prosječno vrijeme isporuke
- d^2 – kvadrat prosječne potražnje d
- σ_L^2 – varijanca vremena isporuke
- *z vrijednost* - broj standardnih devijacija za vjerojatnost željene razine usluge

Primjer 2. Izračunajte sigurnosne zalihe i točku postavljanja narudžbe ako je razina usluge prema kupcu 95%, a podaci (prognoze) o dnevnim potražnjama i vremenima isporuke su:

Potražnja	Vrijeme isporuke
100	2
105	3
98	1
102	2
95	4
98	2
100	1
104	4
98	3

Rješenje.

Točka postavljanja narudžbe je $R = \overline{L} \cdot d + SZ$, gdje je d prosječna potražnja.

	A	B	C	D	E	F	G	H	I	J	K
1											
2		**Potražnja**						**Vrijeme isporuke**			
3		100		Prosječna potražnja	=AVERAGE(B3:B11)			2		Prosječno vrijeme isporuke	=AVERAGE(H3:H11)
4		105						3			
5		98						1			
6		102		Varijanca	=VAR(B3:B11)			2		Varijanca	=VAR(H3:H11)
7		95		Razina usluge	0,95			4			
8		98						2			
9		100		z vrijednost	=NORM.S.INV(E7)			1			
10		104						4			
11		98						3		**Sigurnosne zalihe**	=E9*SQRT(E6*K3+E3^2*K6)
12											
13										**Točka postavljanja narudžbe**	=K3*E3+K11
14											

	A	B	C	D	E	F	G	H	I	J	K	L
1												
2		**Potražnja**						**Vrijeme isporuke**				
3		100		Prosječna potražnja	100,00			2		Prosječno vrijeme isporuke	2,44	
4		105						3				
5		98						1				
6		102		Varijanca	10,25			2		Varijanca	1,28	
7		95		Razina usluge	0,95			4				
8		98						2				
9		100		z vrijednost	1,644854			1				
10		104						4				
11		98						3		**Sigurnosne zalihe**	186,1145	
12												
13										**Točka postavljanja narudžbe**	430,5590	
14												

Budući da je prosječna potražnja jednaka 100, uočimo da sa sigurnosnim zalihama *SZ = 186,1145* pokrivamo otprilike dva dana.

4.3.3. Konstantna potražnja, varijabilno vrijeme isporuke

U slučaju da je potražnja konstantna, a vrijeme isporuke varijabilno, sigurnosne se zalihe računaju po formuli:

$$SZ = z \cdot \sqrt{d^2 \sigma_L^2}$$

ili

$$SZ = z \cdot d \cdot \sigma_L$$

gdje su:

- d – potražnja
- σ_L – standardna devijacija vremena isporuke
- *z vrijednost* - broj standardnih devijacija za vjerojatnost željene razine usluge

Primjer 3. Izračunajte sigurnosne zalihe i točku postavljanja narudžbe ako je razina usluge prema kupcu 95%, potražnja konstantna i iznosi 100 za svaki period, a podaci vremenima isporuke su:

Vrijeme isporuke
2
3
1
2
4
2
1
4
3

Rješenje.

Koristit ćemo formulu $SZ = z \cdot d \cdot \sigma_L$, gdje je *d = 100.* Točka postavljanja narudžbe je $R = \overline{L} \cdot d + SZ$, gdje je $\overline{L}$ prosječno vrijeme isporuke.

	A	B	C	D	E	F	G	H
1								
2		Potražnja			Vrijeme isporuke			
3		100			2		Prosjek	=AVERAGE(E3:E11)
4		100			3		Standardna devijacija	=STDEV(E3:E11)
5		100			1		Razina usluge	0,95
6		100			2		z vrijednost	=NORM.S.INV(H5)
7		100			4		**Sigurnosne zalihe**	=H6*B3*H4
8		100			2			
9		100			1		**Točka postavljanja narudžbe**	=H3*B3+H7
10		100			4			
11		100			3			
12								

	A	B	C	D	E	F	G	H
1								
2		Potražnja			Vrijeme isporuke			
3		100			2		Prosjek	2,44
4		100			3		Standardna devijacija	1,13
5		100			1		Razina usluge	0,95
6		100			2		z vrijednost	1,644854
7		100			4		**Sigurnosne zalihe**	185,9323
8		100			2			
9		100			1		**Točka postavljanja narudžbe**	430,3768
10		100			4			
11		100			3			
12								

4.4. Klasifikacija zaliha

Da bismo upravljali zalihama moramo angažirati svoje resurse, pa to predstavlja trošak. Ukoliko se bavimo svim stavkama na zalihama trošak može biti popriličan. Pa se postavlja pitanje „Treba li voditi računa o svim proizvodima na zalihama ili samo nekima?“. Ukoliko ćemo se baviti samo nekim proizvodima, koji su kriteriji odabira tih proizvoda? Tj., koji su nam proizvodi najvažniji i zašto?

Svako poduzeće na ovo pitanje ima svoj odgovor koji ovisi o kriterijima po kojem određujemo koja je stavka važna, a koja i nije previše. Ti kriteriji ne moraju biti isti za sva poduzeća iako se neki pojavljuju skoro uvijek (na primjer, promet, stabilna potražnja, pouzdanost dobavljača i slično).

4.4.1. ABC klasifikacija zaliha

Jedna od najpoznatijih klasifikacija zaliha je ABC klasifikacija koja rangira stavke na zalihama po kriteriju udjela u ukupnoj vrijednosti. Nakon što se stavke rangiraju od one s najvećim udjelom do one s najmanjim udjelom, izračunaju se kumulativi udjela. U skladu s tim, kreira se klasifikacija počevši od prve stavke:

- Kategorija A – stavke koje čine 80% ukupne vrijednosti zaliha
- Kategorija B – stavke koje čine daljnjih 15% vrijednosti zaliha
- Kategorija C – stavke koje čine daljnjih 5% vrijednosti zaliha

Po Paretovom pravilu, uglavnom na kraju dobijemo da 20% stavki čini 80% vrijednosti, 30% stavki čini daljnjih 15% vrijednosti, te 50% stavki čini zadnjih 5% vrijednosti. To u praksi naravno ne mora biti tako precizno, te ovisi i o našim procjenama.

4.4.2. XYZ klasifikacija zaliha

Sljedeća poznata klasifikacija zaliha je XYZ klasifikacija koja rangira stavke na zalihama po kriteriju varijabilnosti potražnje:

- Kategorija X – potražnja niske varijabilnosti
- Kategorija Y – potražnja srednje varijabilnosti
- Kategorija Z – potražnja visoke varijabilnosti

Varijabilnost potražnje se mjeri pomoću koeficijenta varijacije. Koeficijent varijacije je omjer standardne devijacije i srednje vrijednosti (prosjeka). Što je koeficijent varijacije manji, potražnja je stabilnija.

$$\text{Koeficijent varijacije} = \frac{\text{Standardna devijacija}}{\text{Srednja vrijednost}}$$

Nakon provedene klasifikacije, zaključujemo:

- Kod kategorije X nije potrebno držati sigurnosne zalihe
- Kod kategorije Y možemo razmisliti u kojem ćemo obimu držati sigurnosne zalihe
- Kod kategorije Z potrebno je držati sigurnosne zalihe

5. Agregatno planiranje

Da bi poduzeće (ili cijeli lanac opskrbe) zadovoljilo potražnju, mora proizvoditi ili distribuirati. Da bi to bilo moguće, poduzeće mora koristiti svoje resurse. A da bi resursi bili dostupni, moraju se planirati. Poduzeće planira dugoročno, srednjoročno i kratkoročno.

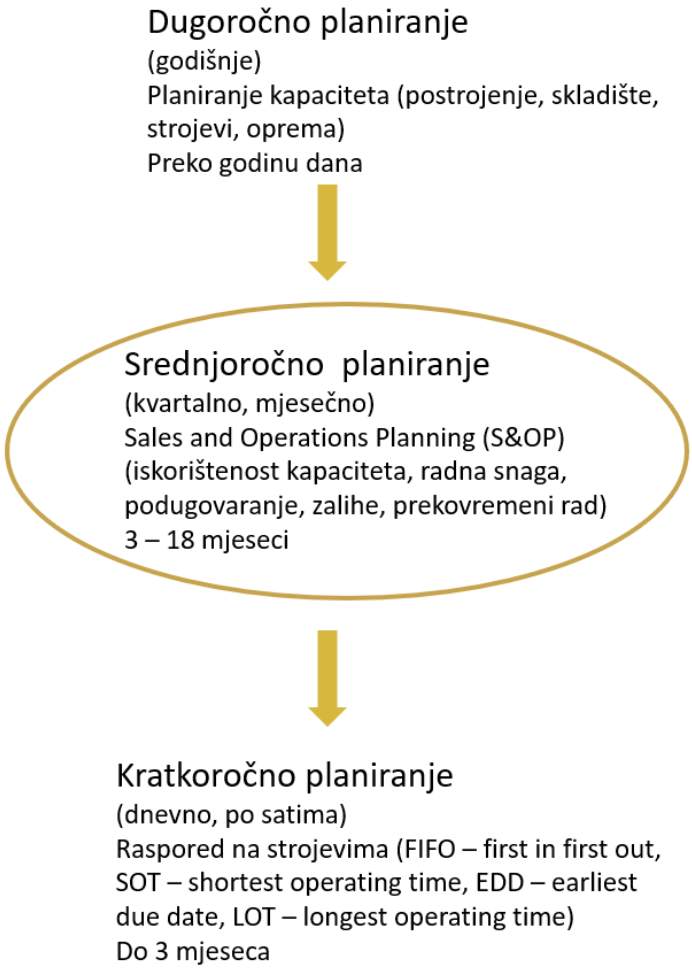

Agregatno planiranje je proces kojim poduzeće definira razinu kapaciteta, proizvodnje, podugovaranja, zaliha, stockout-a, pa čak i razinu cijena za određeni vremenski horizont, a s ciljem zadovoljavanja potražnje i minimiziranja troškova (ili maksimiziranja dobiti). Ono se odvija na srednji rok i rezultat je procesa kojeg nazivamo S&OP (Sales and Operations Planning). Agregatno planiranje, što i sama riječ kaže, znači planirati na agregatnoj razini, a ne na razini proizvoda.

Backlog – nezavršeni proizvod.
Backorder – neizvršena isporuka s namjerom da se izvrši naknadno

Informacije koje su obično potrebne za kreiranje agregatnog plana za određeni vremenski horizont, neke po periodima, su:

- Potražnje po periodima
- Jedinični troškovi proizvodnje periodima
- Vrijeme potrebno za proizvodnju jedne jedinice
- Jedinični trošak držanja zaliha po periodima
- Trošak backlog-a i/ili backorder-a
- Ograničenja na prekovremeni rad, broj otkaza, raspoloživi kapital, stockout
- Ograničenja od strane dobavljača

Na temelju tih informacija, poduzeće kreira agregatni plan pritom radeći trade off među tri stavke:

- Kapacitet (redovno vrijeme, prekovremeni rad, podugovaranje, privremeni zaposlenici)
- Zalihe
- Backlog ili backorder

Da bi se postigla ravnoteža među troškovima ove tri stavke, poduzeće ima tri osnovne strategije agregatnog planiranja:

- Strategija potjere (Chase strategy) – proizvodnja je jednaka potražnji, a kapaciteti strojeva i radne snage se mijenjaju kako se mijenja proizvodnja
- Strategija kapaciteta (Capacity strategy) – radna snaga (kapacitet) je stabilna, ali vrijeme rada nije. Moguće je uvesti prekovremeni rad da bi se uravnotežile proizvodnja i potražnja
- Strategija zaliha (Inventory strategy) – kapaciteti i proizvodnja su stabilni. Proizvodnja nije uravnotežena s potražnjom već se kreiraju zalihe unaprijed za zadovoljavanje buduće potražnje ili za nadoknadu backordera.

Strategija kapaciteta i strategija zaliha su poznate i pod zajedničkim nazivom strategija razine.

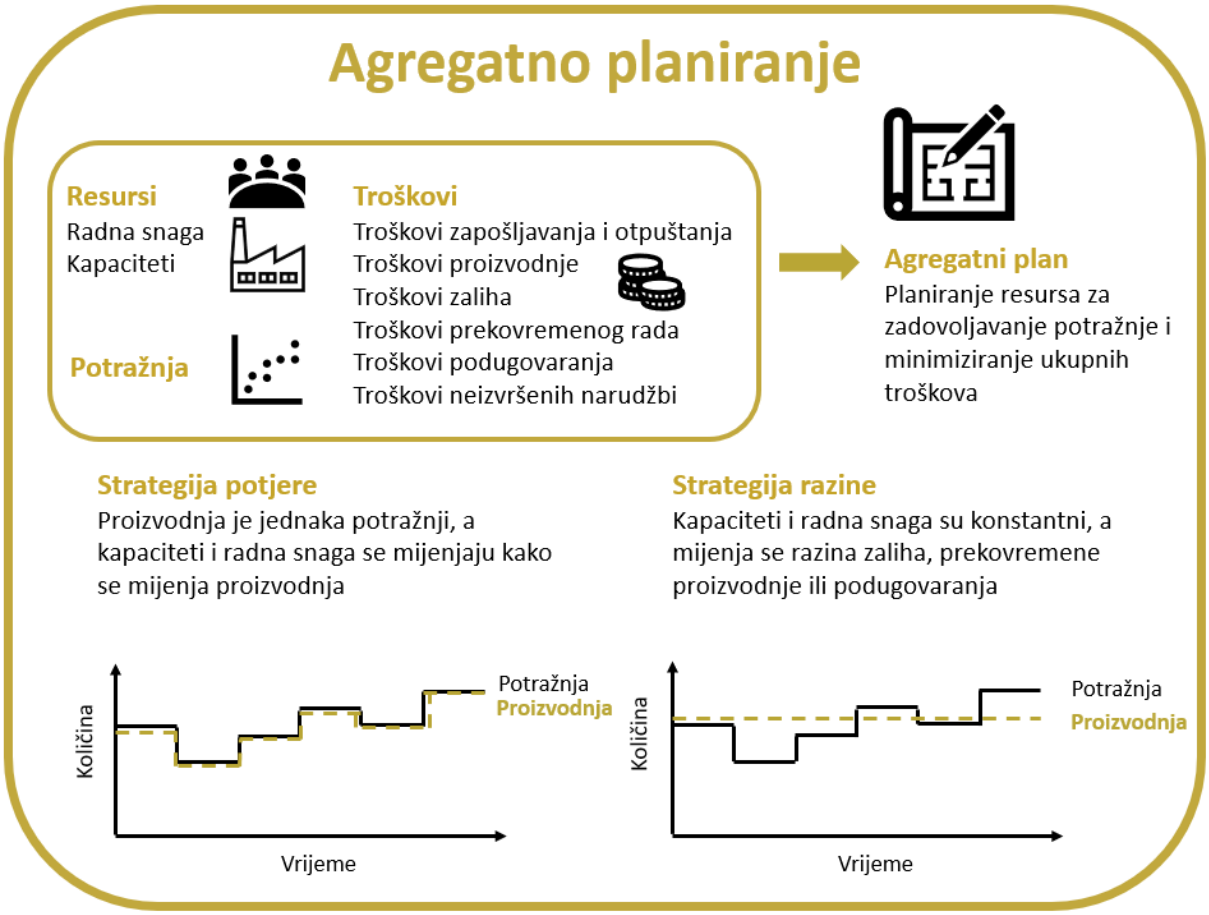

6. Transport

Transport je važna strategija upravljanja lancem opskrbe jer se proizvodi rijetko proizvode i prodaju na istom mjestu. Isto vrijedi i za usluge. Da bi usluga bila moguća potrebni su proizvodi koji se prevoze od dobavljača do mjesta pružanja usluge. Transport se odnosi na premještanje sirovina i proizvoda od jedne do druge lokacije u lancu opskrbe, počevši od prvog dobavljača do krajnjeg kupca. Kao i kod ostalih strategija upravljanja lancem opskrbe i kod transporta je cilj uglavnom minimizirati troškove.

Transportnu mrežu možemo promatrati kao usmjereni graf, tj., kao skup čvorova i bridova. Problem optimizacije transporta je onda odrediti količine koje će se prevoziti od jednog čvora do drugog minimizirajući troškove transporta.

6.1. Problem transporta kao problem linearnog programiranja

Primjer 1. Uzorke proizvoda namijenjene promidžbi potrebno je iz dva distribucijska centra, S_1 i S_2, prevesti na tri prodajna mjesta, P_1, P_2 i P_3 tako da ukupni troškovi transporta budu minimalni. Količine uzoraka u distribucijskim centrima, potrebne količine uzoraka na prodajnim mjestima i cijene transporta jednog uzorka iz određenog distribucijskog centra na određeno prodajno mjesto, dani su u sljedećoj tablici:

Distribucijski centar	Prodajno mjesto			Kapaciteti distribucijskih centara
	P_1	P_2	P_3	
S_1	2	3	5	10
S_2	4	7	6	8
Potrebe (kapaciteti) prodajnih mjesta	7	6	5	

Odredite količine prevezenih uzoraka tako da transportni troškovi budu minimalni.

Rješenje.

Varijable odlučivanja:

x_{ij} količina uzoraka prevezenih iz *i-tog* distribucijskog centra na *j-to* prodajno mjesto (odredište), $i = 1,2; j = 1,2,3$

Distribucijski centar	Prodajno mjesto		
	P_1	P_2	P_3
S_1	x_{11}	x_{12}	x_{13}
S_2	x_{21}	x_{22}	x_{23}

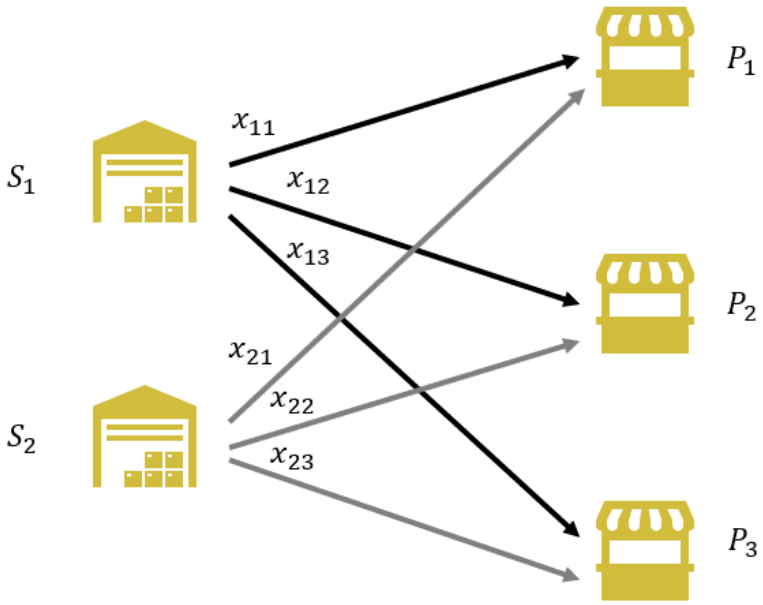

Model linearnog programiranja:

$$\min(2x_{11} + 3x_{12} + 5x_{13} + 4x_{21} + 7x_{22} + 6x_{23})$$

$$x_{11} + x_{12} + x_{13} = 10$$

$$x_{21} + x_{22} + x_{23} = 8$$

$$x_{11} + x_{21} = 7$$

$$x_{12} + x_{22} = 6$$

$$x_{13} + x_{23} = 5$$

$$x_{ij} \geq 0, i = 1,2; j = 1,2,3$$

U Excelu to izgleda ovako:

	A	B	C	D	E	F	G
1							
2		Distribucijski centar	Prodajno mjesto			Kapaciteti distribucijskih centara	
3			P1	P2	P3		
4		S1	2	3	5	10	
5		S2	4	7	6	8	
6		Potrebe (kapaciteti) prodajnih mjesta	7	6	5		
7							
8							
9		Distribucijski centar	Prodajno mjesto			Zbroj	
10			P1	P2	P3		
11		S1				=SUM(C11:E11)	
12		S2				=SUM(C12:E12)	
13		Zbroj	=SUM(C11:C12)	=SUM(D11:D12)	=SUM(E11:E12)		
14							
15							
16		Ukupni troškovi	=SUMPRODUCT(C4:E5;C11:E12)				
17							
18							
19							

	A	B	C	D	E	F	G
1							
2		Distribucijski centar	Prodajno mjesto			Kapaciteti distribucijskih centara	
3			P1	P2	P3		
4		S1	2	3	5	10	
5		S2	4	7	6	8	
6		Potrebe (kapaciteti) prodajnih mjesta	7	6	5		
7							
8							
9		Distribucijski centar	Prodajno mjesto			Zbroj	
10			P1	P2	P3		
11		S1				0	
12		S2				0	
13		Zbroj	0	0	0		
14							
15							
16		Ukupni troškovi	0				
17							

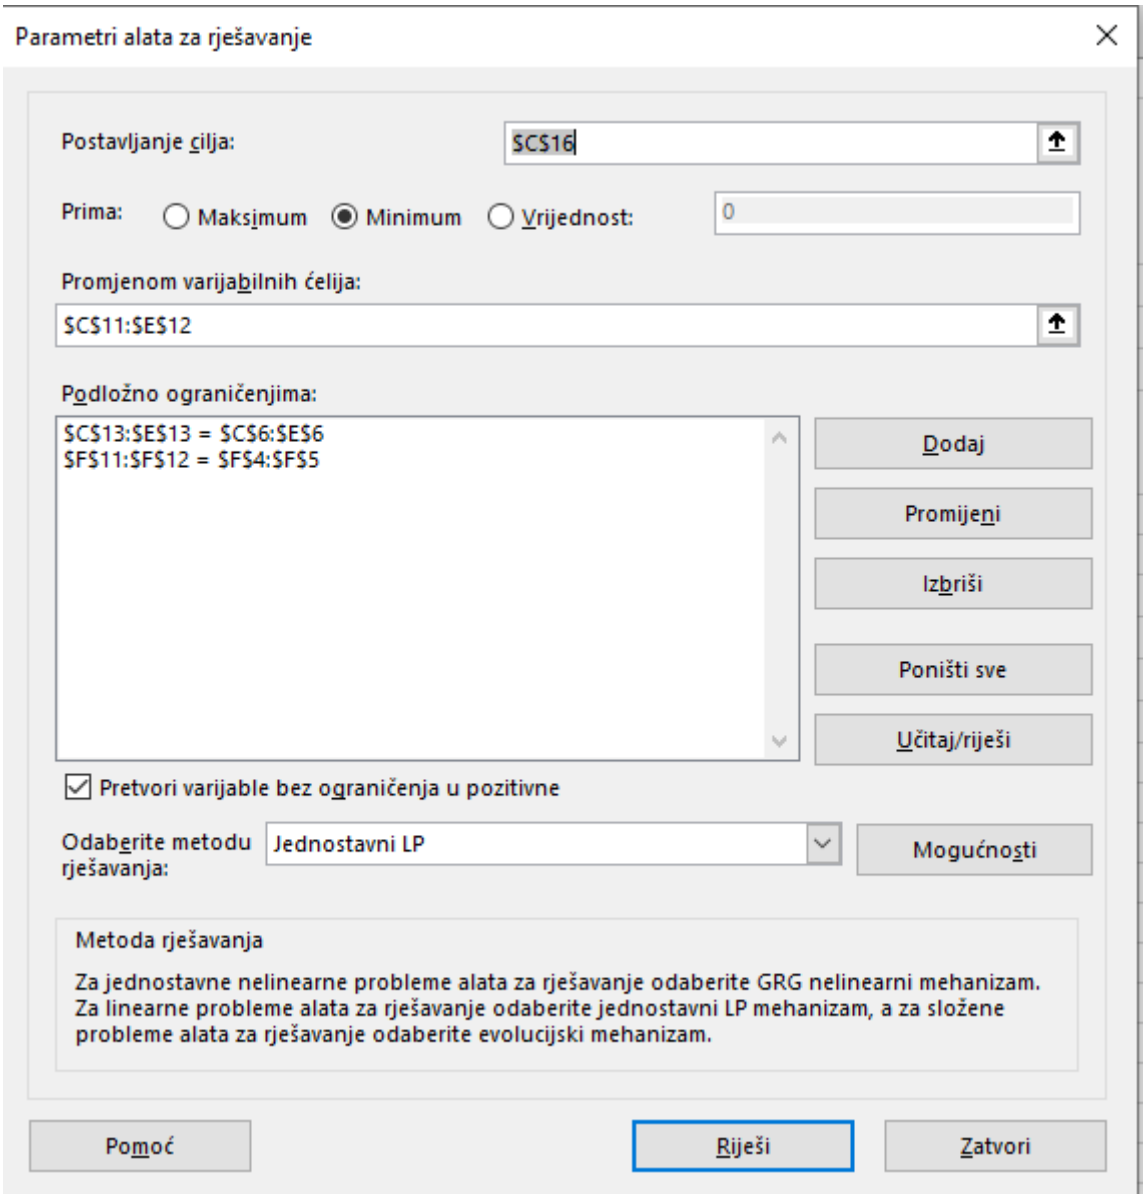
Parametri alata za rješavanje
Postavljanje cilja:
$C$16
Prima:
Maksimum
Minimum
Vrijednost:
0
Promjenom varijabilnih ćelija:
$C$11:$E$12
Podložno ograničenjima:
$C$13:$E$13 = $C$6:$E$6
$F$11:$F$12 = $F$4:$F$5
Dodaj
Promijeni
Izbriši
Poništi sve
Učitaj/riješi
Pretvori varijable bez ograničenja u pozitivne
Odaberite metodu rješavanja:
Jednostavni LP
Mogućnosti
Metoda rješavanja
Za jednostavne nelinearne probleme alata za rješavanje odaberite GRG nelinearni mehanizam. Za linearne probleme alata za rješavanje odaberite jednostavni LP mehanizam, a za složene probleme alata za rješavanje odaberite evolucijski mehanizam.
Pomoć
Riješi
Zatvori

Distribucijski centar	Prodajno mjesto			Kapaciteti distribucijskih centara
	P1	P2	P3	
S1	2	3	5	10
S2	4	7	6	8
Potrebe (kapaciteti) prodajnih mjesta	7	6	5	

Distribucijski centar	Prodajno mjesto			Zbroj
	P1	P2	P3	
S1	4	6	0	10
S2	3	0	5	8
Zbroj	7	6	5	

Ukupni troškovi	68

Optimalno rješenje je iz S_1 prevesti 4 jedinice u P_1 i 6 jedinica u P_2. Iz S_2 će se prevesti 3 jedinice u P_1 i 5 jedinica u P_3. Minimalni ukupni troškovi su 68.

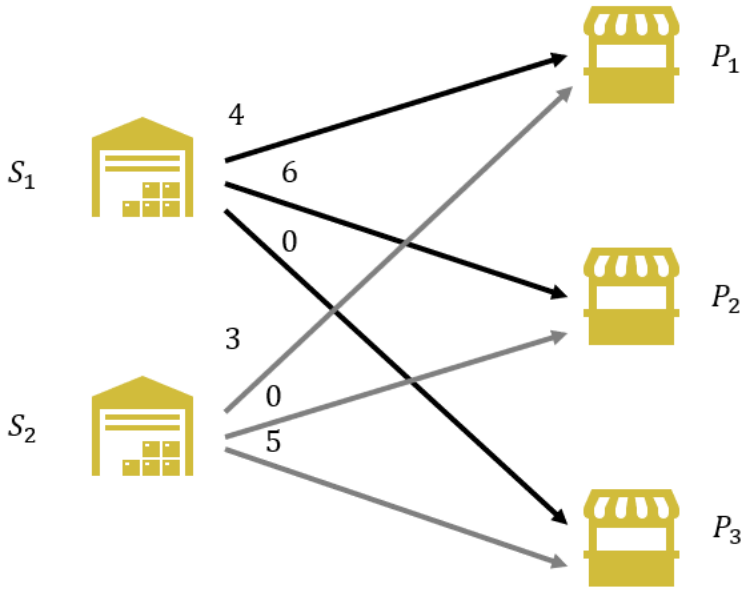

7. Upravljanje odnosima s dobavljačima

Suradnja i komunikacija u lancu opskrbe sve više dolaze do izražaja. Bez njih lanac opskrbe ne postoji! Tome još moramo dodati integriranost i koordinaciju lanca opskrbe, transparentnost i međusobno povjerenje među članovima lanca. Jedan od načina da se svi ti elementi ostvare u lancu opskrbe je i upravljanje odnosima s dobavljačima koje, između ostalog, uključuje:

- Evaluacija i selekcija dobavljača
- Pregovaranje o uvjetima nabave (cijena, uvjeti dostave)
- Komunikacija (dijeljenje planova nabave i prodaje, plasiranje narudžbi)
- Evaluacija

Komunikacija uključuje partnerske odnose koji se ostvaruju kroz:

- Dijeljenje podataka putem platformi
- Dobavljači vode računa o zalihama kod naručitelja (Vendor Management System)
- Dobavljači se udružuju prema naručitelju, naručitelji se udružuju prema dobavljaču
- Dijeljenje znanja

Na kraju treba voditi računa da su odnosi s dobavljačima samo dio zajednice odnosa s ostalim elementima u lancu opskrbe.

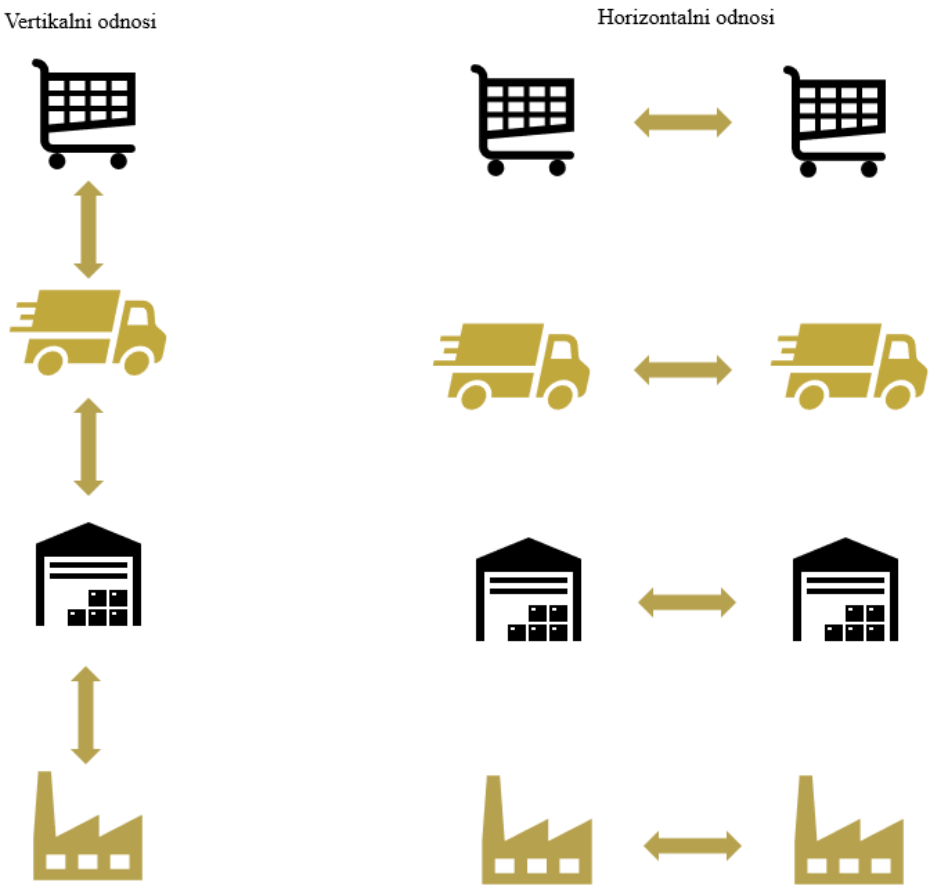

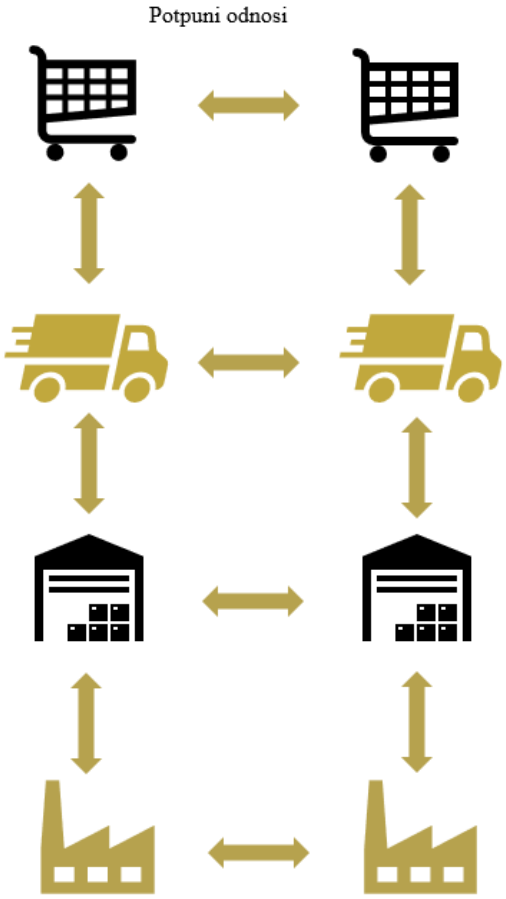

U ovom ćemo poglavlju obraditi evaluaciju i selekciju dobavljača, tj., matematičke metode koje pritom možemo primijeniti. Fokusirat ćemo se na višekriterijsku evaluaciju, a pritom možemo koristiti razne kriterije:

- Cijena
- Kvaliteta
- Tehničke karakteristike proizvoda/usluge
- Rok isporuke
- Točnost isporuke (točna količina)
- Fleksibilnost
- Održivo poslovanje
- Društvena odgovornost
- Zeleno poslovanje
- Sigurnost
- Način dostave
- Prateće usluge
- ...

Postoje konceptualne metode višekriterijskog odlučivanja kao brainstorming i Delphi metoda. Odluke se donose timski, razgovorom, uvažavanjem, traženjem kompromisa tako da su svi zadovoljni. Vrlo je važno ovo zadnje, a to je da su svi zadovoljni. Na taj će način svi preuzeti svoj dio odgovornosti. Proces odlučivanja može biti poduprt i nekom od matematičkih metoda kao što je metoda ponderiranog skora, TOPSIS (Technique for Order of Preference by Similarity to Ideal Solution) metoda, AHP (Analytic Hierarchy Process), ciljno programiranje i ostale.

No, koncept je uvijek isti. Ili svakom kriteriju i opciji koja je u razmatranju dodijelimo pondere (težine) i onda izračunamo konačan ponderirani skor ili kreiramo nepostojeće idealno rješenje, pa tražimo postojeću opciju koja mu je najbliža. Na taj način ne računamo optimalno rješenje već kompromisno ili Pareto efikasno rješenje jer su kriteriji općenito u konfliktu. Što to znači? Ukoliko je cijena ponude niska, onda je i kvaliteta uglavnom niska. Ukoliko je cijena visoka, onda je i kvaliteta uglavnom visoka. Dakle, teško ćemo pronaći ponudu visoke kvalitete i niske cijene.