Analiza logističkog sustava veleprodajne tvrtke

Butina, Saša

Master's thesis / Diplomski rad

2015

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:119:608359

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

Saša Butina

ANALIZA LOGISTIČKOG SUSTAVA VELEPRODAJNE TVRTKE

DIPLOMSKI RAD

Zagreb, 2015.

Sveučilište u Zagrebu
FAKULTET PROMETNIH ZNANOSTI
Vukelićeva 4, 10000 Zagreb
DIPLOMSKI STUDIJ

Diplomski studij: Logistika i ITS
Zavod: Zavod za transportnu logistiku
Predmet: Unutarnji transport i skladištenje

ZADATAK DIPLOMSKOG RADA

Pristupnik: Saša Butina
Matični broj: 1012987330084
Smjer: Logistika

ZADATAK:

Analiza logističkog sustava veleprodajne tvrtke

ENGLESKI NAZIV ZADATKA:

Analysis of Wholesale Logistic Systems

Opis zadatka:

Veleprodajne tvrtke imaju specifičnu ulogu u opskrbnom lancu. Ne djeluju kao klasični posrednik, već često imaju i ulogu da unapređuju distribuciski sustav i podupiru subjekte koji su dio distribucijske mreže. U radu će kandidat opisati sve segmente logističkog sustava veleprodajne tvrtke s posebnim naglaskom na metode prognoziranja logiatičkih kapaciteta. Na primjeru stvarne veleprodajne tvrtke potrebno je usporediti pojedine metode prognoze potražnje i predložiti najpogodniju metodu za odabrani slučaj.

Zadatak uručen pristupniku:
28. lipanj 2015.

Nadzorni nastavnik: Predsjednik povjerenstva za diplomski ispit:

Djelovođa:

Sveučilište u Zagrebu
Fakultet prometnih znanosti

DIPLOMSKI RAD

ANALIZA LOGISTIČKOG SUSTAVA VELEPRODAJNE TVRTKE

ANALYSIS OF WHOLESALE LOGISTIC SYSTEMS

Mentor: Prof. dr. sc. Kristijan Rogić
Student: Saša Butina, 0268008736

Zagreb, 2015.

ANALIZA LOGISTIČKOG SUSTAVA VELEPRODAJNE TVRTKE

SAŽETAK

Analizom logističkog sustava veleprodajne tvrtke obraditi će se veleprodajni operativni skladišni sustav, način analize i povećanja iskorištenja skladišnog kapaciteta, pregled karakteristika skladišne suprastrukture s obzirom na robu koja se na nju pohranjuje, karakteristike robe, načini organizacije uskladištenja robe s ciljem smanjenja vremena pohrane i prikupa te povećanja iskorištenja infrastrukturnog i suprastrukturnog prostora, optimiziranje nivoa zaliha prema potražnji i na kraju kvantitativne metode prognoze potražnje. Cilj istraživanja je konsolidacija veleprodajnog sustava kao cjeline gdje se detaljno analiziraju i uspostavljaju optimalna rješenja dostupnim logističkim alatima i metodama. Materija se obrađuje na teoretskoj i praktičnoj razini radi uspoređivanja i kvantificiranja rezultata alata i metoda kojima se obavlja logističko upravljanje. Postignuti rezultati pokazuju da se skladišni sustav sastoji od raznih skladišnih operacija koje imaju svoje funkcije i pripadajuće mjesto unutar sustava. Izvođenje operacija ima svoju svrhu i preduvjete koji moraju biti zadovoljeni da bi se kvalitetno odradile. Iskorištenje skladišnog kapaciteta za pohranu robe ovisi o elementima koji su vezani za način uskladištenja robe. Analizom optimizacija zaliha za veleprodajnu tvrtku najkvalitetnijom se pokazala P metoda s manjim periodom kao najtočnija metoda optimizacije zaliha. Kvantitativna prognoza potražnje koja ima daleko najtočniju prognozu potražnje je Holt Winter multiplikativna metoda jer se najbolje prilagođava prodajnim podacima uzetim iz prakse.

KLJUČNE RIJEĆI: Veleprodaja, skladišne operacije, skladišni kapacitet, skladišna suprastruktura, značajke robe; lokacije; zone; grupiranje; kategoriziranje; optimiziranje zaliha; prognoza potražnje.

ANALYSIS OF WHOLESALE LOGISTIC SYSTEMS

SUMMARY

Analysis of wholesale logistic system will process wholesale warehouse operations, ways of analyzing and maximization usability of warehouse storage capacity, overview of warehouse supractructure characteristics with respect to the goods being stored on in, characteristic of the goods, ways of organizing the storage of goods in order to reduce storage and collection time and increase utilization of the infrastructure and suprastructure space, optimizations of inventory levels towards the demand and quantitative methods of demand forecasting. The research objective is the consolidation of the wholesale system as a whole where available logistical tools and methods are analyzed in detail with goal of establishing the optimal solutions. The topic is processed on a theoretical and practical level in order to compare and quantify the results of the tools and methods used to perform the logistic management. The results show that the storage system consists of a variety of storage operations which have their respective functions and the position within the system. Performing of tis operations has its own purpose and requirements that must be met in order to be professionally done. Utilization of storage capacity for storage of goods depends on the elements that are related to the manner of storage of goods. By analyzing the optimization of inventory for the wholesale business data has shown that the highest quality methods is P method with smaller period because it has the most accurate inventory optimization. Quantitative forecast demand, which has by far the most accurate forecast of demand is Winter Holt multiplicative method because it adapts best to the sales data.

KEYWORDS: Wholesale; warehouse operations; warehouse capacity; warehouse suprastructure; item characteristics; locations; zoning; categorization; inventory optimization; demand forecasting.

Za voljenu

Mandu i Anku.





SADRŽAJ

1. UVOD 1
1. SUSTAV VELEPRODAJE 2
   1.1 ERP SUSTAV 2
   1.2 WMS MODUL 3
2. SKLADIŠNO UPRAVLJANJE 4
   2.1 VRSTE SKLADIŠTA 4
   2.2 OSNOVNI SKLADIŠNI PROCESI I OPERACIJE 6
   2.3 INVENTURA 14
   2.4 POVRAT ROBE 15
   2.5 LJUDSKI POTENCIJALI 17
   2.6 SKLADIŠNA OPREMA 18
3. ZNAČAJKE ROBE I SKLADIŠTENJE 25
   3.1 KARAKTERISTIKE ROBE 25
   3.2 LOKACIJE 28
   3.3 BARKODOVI 30
   3.4 ORGANIZACIJA POHRANE ROBE 32
4. OPTIMIZIRANJE ZALIHA 37
   4.1 TROŠKOVI ZALIHA 38
   4.2 MODELI KONTROLE RAZINE ZALIHA 39
   4.3 KOEFICIJENT OBRTAJA ZALIHA 42
5. PROGNOZA POTRAŽNJE 43
   5.1 TOČNOST PROGNOZE 46
   5.2 KVANTITATIVNE METODE PROGNOZE POTRAŽNJE 47
   5.3 ODABIR METODE PROGNOZE 53
6. ANALIZA PRAKTIČNIH PRIMJERA 54
   6.1 ANALIZA KAPACITETA SUPRASTRUKTURE SKLADIŠTA 54
   6.2 ANALIZA P MODELA 60
   6.3 ANALIZA KVANTITATIVNIH METODA PROGNOZE 66
   6.4 USPOREDBA P MODELA I LJUDSKOG OPERATERA 77
7. ZAKLJUČAK 81
8. POPIS KRATICA 82
9. IZVORI 83
10. POPIS SLIKA 84
11. POPIS DIJAGRAMA 85
12. POPIS TABLICA 86

1. UVOD

Veleprodaja kao sudionik opskrbnog lanca sadrži logistiku koja definira, upravlja i optimizira operacije koje su prisutne tijekom rada takve tvrtke, te pruža potporu kod upravljanja zalihama kroz sofisticirane tehnike optimizacije zaliha. Ovaj rad obrađuje metode i analize koje su bitne za veleprodajne tvrtke koje se bave gotovim proizvodima široke potrošnje.

Izazovi rastuće veleprodajne firme su efektivno i efikasno upravljanje nad operativnim procesima i sve većim lagerom radi zadovoljenja projicirane potražnje unutar ograničenog prostora skladišnog objekta, s time da se izbjegava stvaranje troška kojeg generiraju ne optimizirani procesi koje posao zahtijeva da postoje. Postojanje i rad veleprodaje bez uporabe modernih alata i metoda upravljanja skladišnih sustava i zaliha jamči stvaranje troška i ugrožava likvidnost firme.

Cilj diplomskog rada je razrada i uspoređivanje logističkih rješenja koje ima na raspolaganju logistički operater kao uporište za bolje sveukupno upravljanje manjom veleprodajnom tvrtkom na razini elemenata skladišne infrastrukture i suprastrukture, skladišnih operacija i zaliha. **Naslov diplomskog rada je: Analiza logističkog sustava veleprodajne tvrtke.** Rad je podijeljen u osam cjelina;

1. Uvod
2. Sustav veleprodaje
3. Skladišno upravljanje
4. Značajke robe i skladištenje
5. Optimiziranje zaliha
6. Prognoza potražnje
7. Analiza praktičnih primjera
8. Zaključak

U drugom poglavlju je objašnjen logistički sustav veleprodaje kao dio operativnog skladišnog sustava. U trećem poglavlju daljnja obrada ulazi u cjelinu skladišnog upravljanja kroz teme podjele veleprodajnog sustava na skladišne operacije kojima je svrha operativna okosnica sustavu, skladišno upravljanje počevši od vrste objekata. U četvrtom poglavlju objašnjena je logika i načini skladištenja zaliha s obzirom na karakteristike zaliha i skladišne regalne opreme. U petom poglavlju obrađuje se optimizacija količina zaliha. U šestom poglavlju obrađuje se kvantitativno predviđanje potražnje. U sedmom poglavlju se obavljene analize kapaciteta skladišnog objekta, kvantitativna usporedba točnosti metoda predviđanja potražnje i kvantitativna usporedba rezultata P modela s obzirom na optimizaciju zaliha.

Obrada tih elemenata omogućava dublje shvaćanje problematike kojom se bavi logistika unutar veleprodajnih tvrtki, što omogućava daljnju razradu kvalitetnijih rješenja i buduću potporu za eventualne nove elemente koje prije nisu postojali a koji će se implementirati u postojeći sustav tijekom njegovog razvitka. Tijekom izrade diplomskog rada korištena su iskustva autora iz poslovanja tvrtke Kineo tehne d.o.o tijekom 2012. do 2015. godine gdje je dio teorije, izračuna i dijagrama bazirano na stvarnim podacima.

1. SUSTAV VELEPRODAJE

Unutar opskrbnog lanca veleprodajne tvrtke su jedan od posrednika koji služe za distribuciju robe dalje niz opskrbni lanac. Veleprodaja može raditi s zalihama sirovima, poluproizvoda ili gotovih proizvoda. U ovom radu će biti obrađeni logistički procesi vezani za gotove proizvode. Veleprodaja može biti sačinjena od raznih funkcija poput: prodaje, izgradnje asortimana, skladištenja, transporta, financijskog i robnog upravljanja itd.

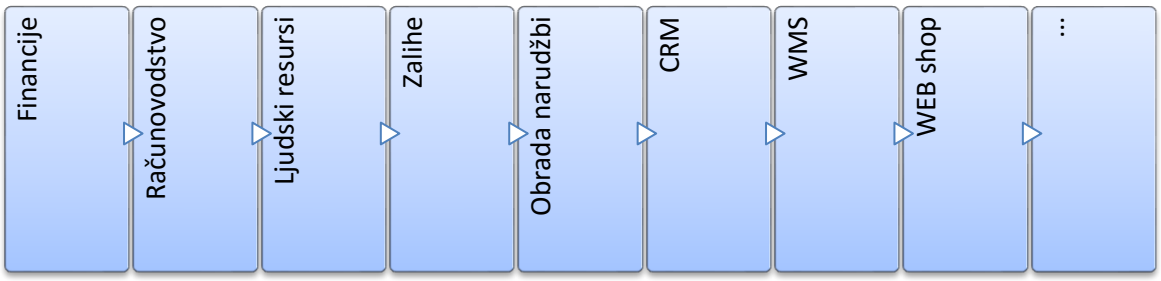
Veleprodaja služi za povezivanje drugih sudionika opskrbnog lanca, objedinjavanje asortimana za maloprodajnu mrežu, objedinjavanje narudžbi radi ostvarenje većih popusta i ostvarivanja dostupnosti kanalima i zalihama koji nisu prisutni manjim tvrtkama, skladištenje zaliha radi smanjenja rizika velikih zaliha kod malih tvrtki, financiraju visoki nivo zaliha s kojim miču rizik velikih lagera s proizvođača te omogućuju pristup zalihama koje si manje tvrtke ne mogu financirati i slično [1,10].

Da bi veleprodaja mogla funkcionirati na operativnoj, taktičnoj i strateškoj razini, njeni procesi i funkcije moraju biti objedinjene. Sustavi koji objedinjuju funkcije prisutne kako u raznim organizacijama tako i u veleprodajnim tvrtkama se zovu ERP sustavi.

1.1 ERP SUSTAV

ERP (*enterprise resource planning* / planiranje resursa poslovnog sustava) omogućuje pogled na procese unutar tvrtke u stvarnom vremenu, koristeći zajedničku bazu podataka. ERP sustav prati resurse poduzeća: novac, zalihe ... te poslovne obaveze: narudžbe, isplate ... ERP omogućuje spajanje i međusobno usklađivanje financijskog i robnog upravljanja. Ovakvi sustavi omogućavaju potporu raznim poslovnim funkcijama. U početku je ERP bio korišten samo od većih tvrtki dok se u današnje vrijeme naveliko koristi i u malim tvrtkama.

Dijagram 1 prikazuje neke od sistema koji su prisutni tijekom rada tvrtke pa su tako i prisutni u ERP-u koji ih međusobno povezuje kroz konsolidaciju u sustav koji omogućava pojedinačno i zajedničko funkcioniranje bez greška s obzirom na međusobnu povezanost. ERP sustavi se razlikuju jer se izvode prema potrebama tvrtke (tj. vrsti industrije) koja će ga koristiti. Jedan od dva poznata ERP sustava su: *SAP* i *Microsoft Dynamics Navision*. U ovom radu će biti pojašnjeni sistemi upravljanja zalihama, organizacije skladišta i predviđanja potražnje.



Dijagram 1 – Neki od modula ERP sustava. [1,6,7]

ERP sustavi se mogu sastojati od sistema [6,7]:

- Financije – glavna knjiga, fiksna imovina, usklađivanje i isplata potraživanja, upravljanje gotovinom, financijska konsolidacija;
- Ljudski resursi – zapošljavanje, obuka, plače, beneficije;
- Obrada narudžbi – unos narudžbi, provjera kreditne sposobnosti, provjera cijena, dostava, analiza prodaje;
- Upravljanje lancem nabave – planiranje lancem, raspored dobavljača, kupnja, skladištenje;
- Upravljanje projektima – projektiranje, planiranje resursa, planiranje troškova, plan rada, performanse jedinicama, upravljanje aktivnostima;
- Upravljanje odnosa s kupcima (CRM) – prodaja i marketing, provizije, uspostava kontakta s kupcima, pozivni centri;
- Podatkovne usluge – sučelja za kupce, dobavljače ili zaposlenike;

Jedan od logistički bitnih modula u ERP sustavu je WMS modul. Referira ga se na kao modul jer ne mora biti nužan dio ERP sustava. Bez obzira, WMS modul je skup alata i procesa koji zajednički omogućavaju u operativnom i logističkom smislu bolje upravljanje nad funkcijama.

1.2 WMS MODUL

WMS (*warehouse management system* / sistem upravljanja skladištem) je ključan dio skladišnog poslovanja koji služi za kompjuteriziranu kontrolu kretanja i skladištenje zaliha unutar skladišta s popratnim operacijama koje uključuju prijem, otpremu i komisioniranje. WMS također služi za organizaciju zaliha s obzirom na stvarne trenutne podatke o stanju zaliha tijekom aktivnih operacija skladišta. WMS također može sadržavati i skladišnu infrastrukturu i suprastrukturu. Neke od informacija koje se vežu za zalihe mogu biti: karakteristike zaliha, lokacije, grupe, dimenzije, mase, skladišne mjerne jedinice ... sve te značajke su bitne za WMS jer se na temelju njih njima upravlja. WMS automatski skuplja podatke putem RFID (*radio frequency identification*) ili barkod skenera. Ovakav modul nije pripadajući za svako skladište, jer je WMS skup za posjedovati i održavati (tvrtke često imaju svoje timove za informacijske tehnologije koji održavaju WMS). Tako da je bitno kod implementacije WMS-a da se odvažu troškovi s koristima. Neke od često navedenih prednosti WMS-a su da se mogu smanjiti troškovi rada, povećati skladišni kapacitet, uslugu kupcima i osigurati veću točnost kod upravljanja s zalihama na fizičkoj razini.

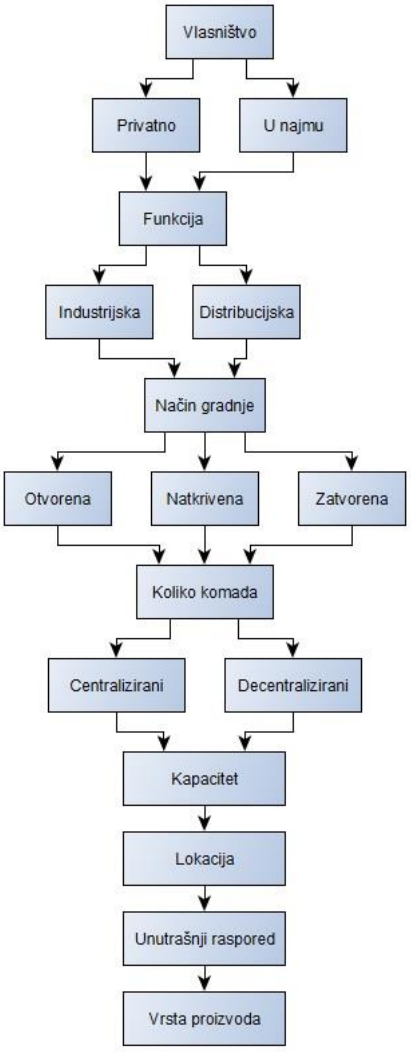
U stvarnosti smanjenje troška radne snage je ostvareno ako je trošak IT kadra manji od uštede troška radnika unutar samog skladišta. Povećanje usluge kupcima se također ostvaruje ako se smanji vrijeme obrade, komisioniranja i otpreme. Povećanje skladišnog kapaciteta zbog WMS modula i nije nužno ostvarivo ako se skladišti na kaotični način uskladištenja robe gdje se ista odlaže na najdostupnije regale zbog uštede na vremenu, što uzrokuje skladištem bez prevelikog obzira na iskoristivost skladišta. WMS u praksi omogućuje smanjenje vremena faza prijema, komisioniranja i otpreme.

2. SKLADIŠNO UPRAVLJANJE

Skladišta su sustavi kojima je uloga skladištenje i čuvanje zaliha s svrhom zadovoljenja potražnje tržišta [1,3]. Prva bitna logistička odluka vezana za veleprodajnu tvrtku je koja će se vrsta skladišta i na kojoj lokaciji koristiti tijekom njenog poslovanja. Nadalje treba pojmiti skladišne operacije i procese (te njihovu kvantifikaciju) koje one čine da bi se mogao formirati skladišni sustav temeljem kojega će se vršiti logističko upravljanje. Poznavanjem skladišnog sustava i vrsti zaliha projektira se skladišna suprastruktura s ciljem maksimiziranja iskorištenja prostora.

2.1 VRSTE SKLADIŠTA

Roba može biti različitih veličina, masa, pakiranja te ostalih karakteristika. Njihovo rukovanje i skladištenje ovisi o tim karakteristikama. Vrsta aktivnosti određene vrstom subjekta u opskrbnom lancu, dizajn te kapacitet skladišta i njegova lokacije određuje kakvo će se skladište odabrati za svoju ulogu. Slika 1 pokazuje neke od kriterija koji su prisutni kod odabira skladišta:



Slika 1 - Dijagram toka koraka odabira skladišta. [3]

Vlasništvo [3]:

- privatno – pod vlasništvom tvrtke ili osobe koja posjeduje tvrtku;
- u najmu – iznajmljivanje skladišta.

Količina [3]:

- Centralizirano skladištenje - omogućuje upravljanje na lokalnoj razini gdje je logistički operater upoznat s prisutnim faktorima. Nedostatak im je da upravljanje zalihama može biti odrađeno nekvalitetno jer zaduženi operater vodi upravljanje na subjektivnoj razini. Centralizirana skladišta imaju tendenciju visokih količina zaliha;
- Decentralizirano skladištenje - omogućuje udaljenje od dnevnih aktivnosti prisutnih u skladišnim jedinicama što omogućuje objektivniji pristup upravljanju. Decentralizirani sustavi skladišta omogućuju smanjenje zaliha putem metode objedinjavanja rizika. Problem decentraliziranih skladišta je neupućenost u lokalne događaje.

Kapacitet - Skladišni kapacitet je bitan u odnosu na karakteristike zaliha. Kapacitet ovisi o broju skladišnih jedinica, također bitna je i vrijednosna gustoća proizvoda jer u slučaju da tvrtka prodaje proizvode koji su većih dimenzija, manje vrijednosne gustoće a većeg koeficijenta obrtaja biti će nužno uzeti veći objekt. Također valja uzeti u obzir moguću uporabu skladišne i transportne opreme koje će možda biti nužna za korištenje.

Lokacije skladišta - kriteriji određivanja lokacije skladišta [3]:

- Trošak distribucije na tržište;
- Dostupnost objekt različitim vrstama prijevoza;
- Troškovi distribucije;
- Prisutnost konkurencije;
- Dostupnost komunalija;
- Dostupnost radne snage;
- Potrebe i ograničenja tvrtke;
- Mogućnost budućeg širenja;
- Troškovi najma ili izgradnje;
- Mogućnost promjene lokacije.

Raspored - unutrašnji raspored prostorija skladišnog objekta znatno utječe na iskoristivost skladišnog prostora, tj. prikladnost za primjenu potrebitih regala i skladišne i transportno manipulacijske opreme.

Vrsta proizvoda [3]:

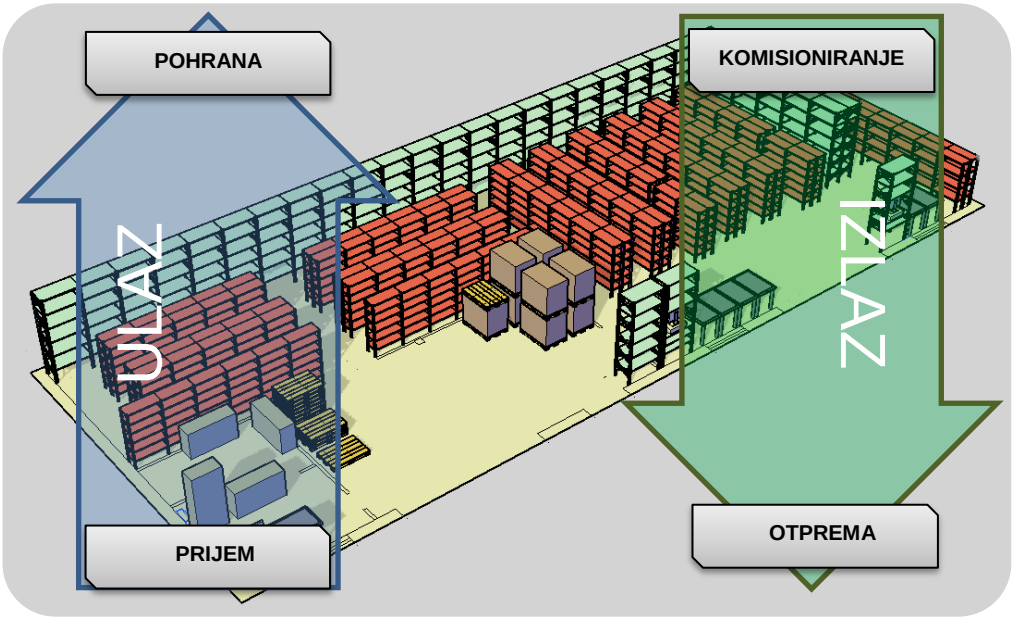
- Za opće namjene (više vrsta roba);
- Za opasne tvari;
- Za tekuće terete, silosi;
- Za visokovrijednu robu;
- Za prehrambene proizvode;
- Sa kontroliranim klimatskim uvjetima;
- Carinska skladišta.

Problem odabira skladišta je složen te zahtjeva poznavanje kriterija koji se vežu za vrstu sudionika u opskrbnom lancu, tj. način poslovanja kojim će se ta tvrtka baviti.

2.2 OSNOVNI SKLADIŠNI PROCESI I OPERACIJE

Osnovne skladišne operacije su: prijem, pohrana, komisioniranje i otprema [1,3]. Navedene operacije se sastoje od višestrukih aktivnosti koji se međusobnim nadovezivanjem sklapaju u određene operacije koje čine dvije glavne vrste skladišnog procesa: ulaz robe u skladište i izlaz robe iz skladišta. Uz navedene procese postoje još i zasebne operacije koje prisutne u skladišnom sustavu a nisu dio dva glavna procesa, to su: inventura, skladišno projektiranje, upravljanje zalihama i povrat robe u skladišni sustav u obliku reklamacije. Te dodatne operacije će također biti obrađene u danjem tekstu. Nadalje obraditi će se u i utjecaj ljudskih potencijala na skladišni sustav, te vrste skladišne regalne opreme.

Slika 2 pokazuje izgled manjeg skladišta na kojemu će se temeljiti prikaz skladišnih operacija i izračuni kod projektiranja skladišne suprastrukture. Skladište je uzeto kao primjer iz stvarnosti.

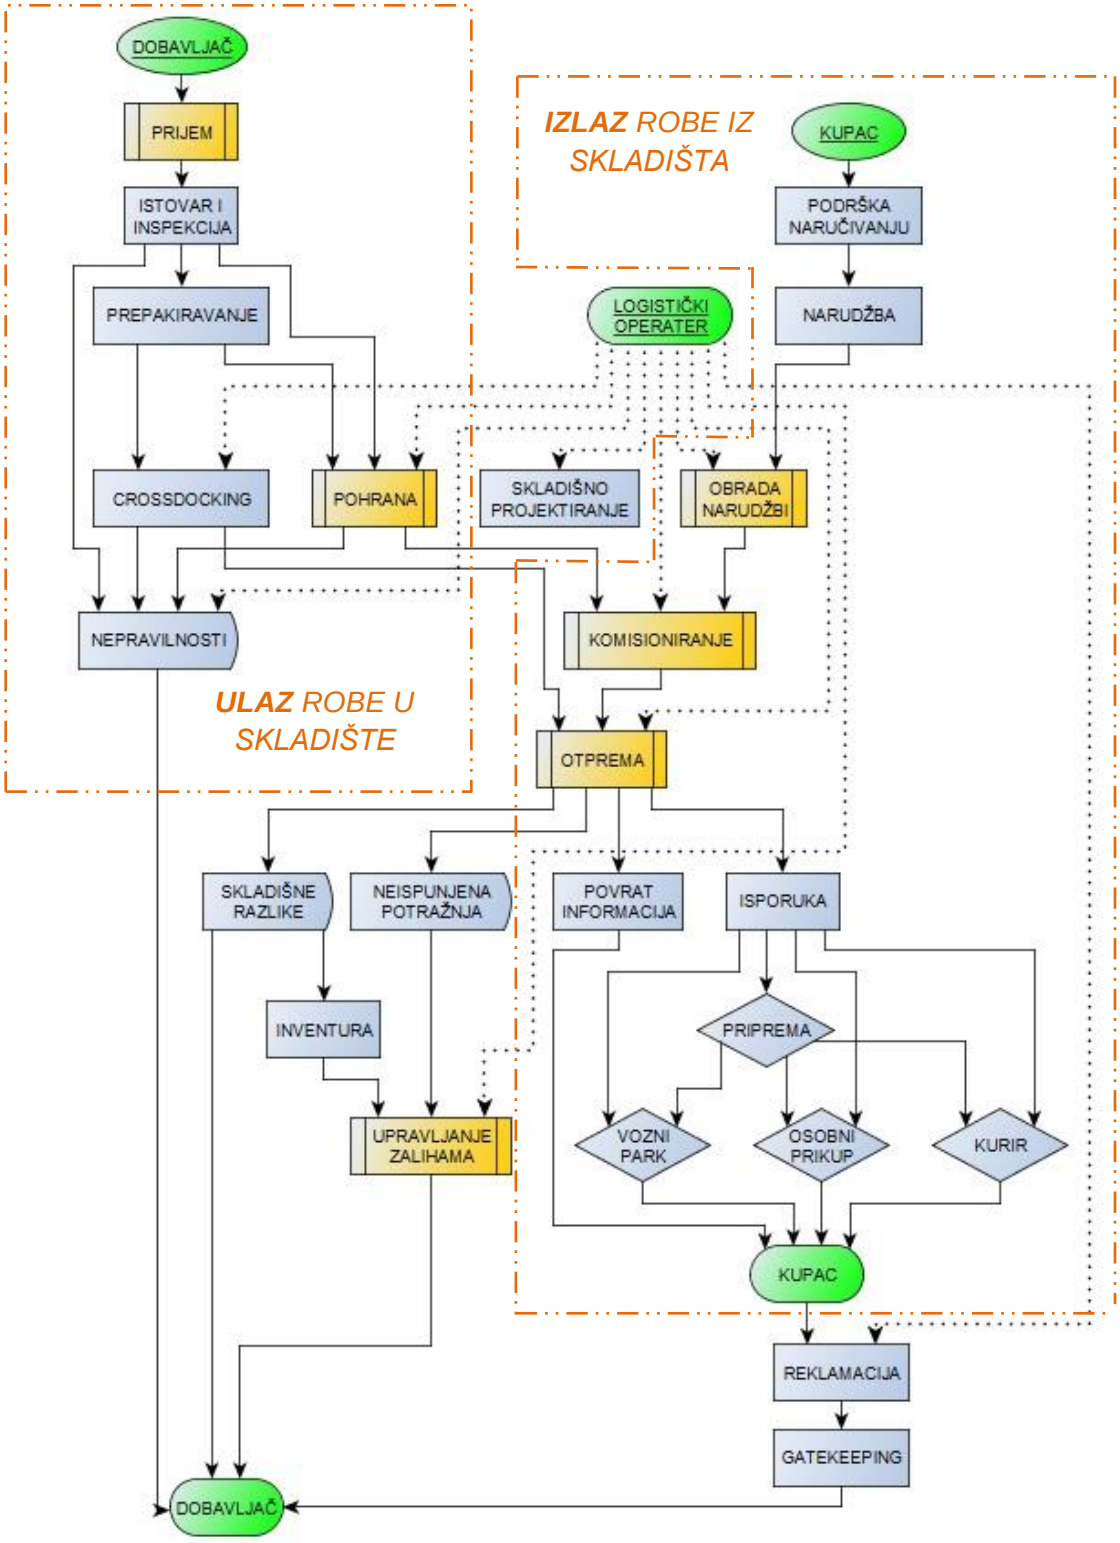


Slika 2 - Prikaz skladišta s osnovnim skladišnim operacijama. [1]

Svaka od skladišnih operacija sadrži više aktivnosti koje ih čine njihovim objedinjenjem, dok više operacija čine procese koji su dio cjelovitog skladišnog sustava. Slika 3 ilustrira procese skladišnog sustava i njihovu međusobnu povezanost, radi se o sustavu uzetom iz prakse. Na tom sustavu vršiti će se prikazi i objašnjenja spomenutih elemenata.

Uloga logističkog operatera unutar skladišnog sustava obuvača praćenje potražnje radi održavanja optimalnih količina zaliha (više o tome u 4. i 5. poglavlju), obradu narudžbi radi maksimiziranja iskoristivosti narudžbe i izvođenje operativne organizacije koja se bazira na poznavanju procesa tvrtke (skladišne operacije), te na kraju projektiranje skladišne suprastrukture s ciljem postizanje što veće iskoristivosti skladišnog prostora.

Operativno upravljanje skladišnim sustavom se vrši kroz nadgledanje, dizajn i kontrolu procesa, a uključuje odgovornost da procesi vrše efikasno svoju funkciju sa što manje potrebnih resursa i vremena [1,2]. **Slika 3** prikazuje procese skladišnog sustava s popratnim operacijama i aktivnostima koji će se obrađivati u danjem tekstu.



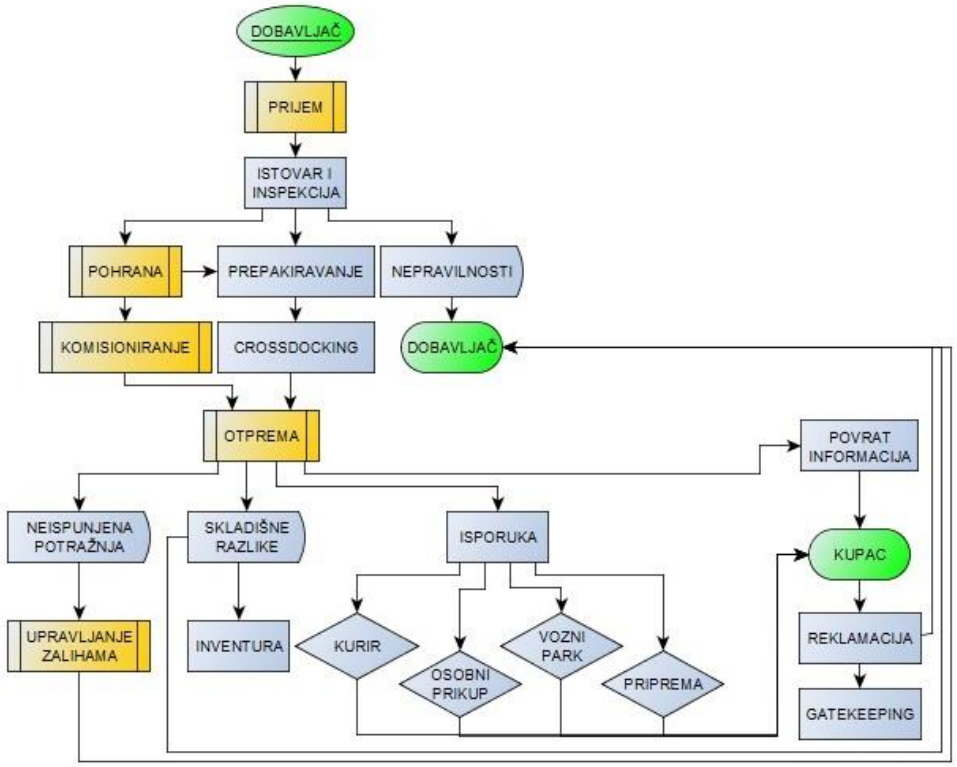
Slika 3 - Procesi skladišnog sustava s osnovnim operacijama i aktivnostima. [1]

2.2.1 PROCES ULAZA ROBE U SKLADIŠTE

Se sastoji od dvije glavne skladišne operacije: prijema i pohrane robe.

1) **Prijem**

Operacija prijema se sastoji od više aktivnosti: istovar robe, inspekcija i pohrana [1,3]. **Slika 4** prikazuje proces ulaza i izlaza robe iz skladišta, gdje je operacija prijema prva operacija na koju se dalje nadovezuju slijedne operacije. Prijemu robe prethodi narudžba distributera (veleprodaje) proizvođaču, više o tome u poglavlju 4 i 5.



Slika 4 - Operacije prijema, cross docking-a, komisioniranja i otpreme. [1]

- Istovar i inspekcija

Broj paleta i/ili koleta se provjerava prilikom istovara i njihovog privremenog smještaja prema računu ili otpremnici koju kurir predaje prilikom primopredaje. Također se obavlja i provjerava kvaliteta stanja koleta/paleta.

- Prepakiranje

Svrha prepakiranja je priprema zaliha za operaciju *crossdockinga*. Prepakiravanje može sadržavati neke korake iz pohrane, no umjesto da se zalihe uskladištavaju na regale one se odmah prepakiravaju za otpremu. Prepakiravanje je operacija koja postoji između pohrane i cross dockinga, te koja se koristi kada se mora obaviti proces koji je mješavina objeg.

2) **Pohrana**

Svrha ove operacije je odlaganje robe na regale, tj. uskladištenje robe. Uključuje i aktivnosti deklariranja, sortiranja, provjere stanja i količine robe s obzirom na primke. Prilikom pohrane robe na regale treba biti oprezan da se ne dogode greške kod prebrojavanja količina zaliha te eventualne zamjene sličnih artikala što bi rezultiralo skladišnim razlikama. Roba se također može krivo raspremiti i temeljem sličnosti izgleda. Također, proizvođač ili dobavljač može greškom poslati krivi proizvod umjesto naručenog, što bi moralo biti vidljivo po primci jer bi trebao biti jedne vrste manjak a druge višak (usporedbom razlika nakon pohrane trebalo bi se primijetiti da je došlo do zamjene). Prilikom provjere razlika iz uvoza obavezno treba zaključiti sve račune. Bitno je kod pohrane da se kod slaganja zaliha na regale pazi na iskoristivost regalnih prostora tako da se slaganje obavi na uredan i smislen način, što također smanjuje vrijeme komisioniranja (više o tome u 3.1). Nakon pohrane zaliha, i njihove konačne provjere zaprimljena roba se pušta na stanje. Koraci koji se vrše prilikom pohrane paletiziranje robe [1]:

- Raspakiravanje;
- Sortiranje;
- Deklariranje;
- Provjera ispravnosti artikla;
- Evidentiranje količinskog stanja;
- Pozicioniranje na stare ili nove lokacije (grupe, ABC, zone ...);
- Provjera razlika za cijelu primku;
- Upis dodatnih primjedbi (barkodova koji nedostaju ...);
- Puštanje zaliha na stanje.

- *Cross-docking* (privremena pohrana)

Sadrži aktivnosti istovara, sortiranja i inspekcije te okrupnjivanja i isporuke. Može sadržavati i raspakiravanje, sortirane, deklariranje, provjeru ispravnosti artikala te evidentiranja količinskog stanja ukoliko za to postoji potreba, tj. obaveza prema kupcu [1,3]. Kod ove robe otprema je trenutačna, ne prolazi proces skladištenja ili ako ga ima kratkotrajan je. Ovakav način pohrane robe omogućuje smanjenje troškova skladištenja i vremena isporuke narudžbi kupcu. U svom najčišćem obliku *cross-docking* sporazumijeva istovar zaliha na prijemu i trenutnu obradu na otpremi i isporuku bez skladištenja. Veleprodajne tvrtke nemaju skladišta koja se primarno bave *cross-docking* operacijama, no zbog načina naručivanja, poput okrupnjivanja narudžbi maloprodajne razine subjekata, određeni dio robe se zaprima u skladište u okrupnjenom stanju na paletama koje se onda „razbijaju“ (*bulk breaking*), te nadalje sortiraju, provjeravaju i ponovno okrupnjuju prema primateljima. Dijagram 2 vizualizira tok te operacije.



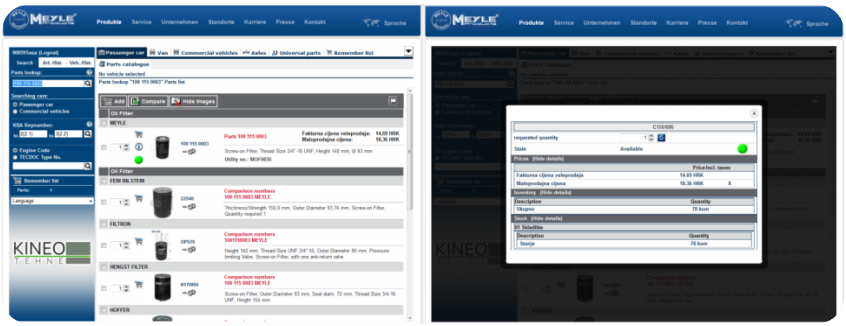
Dijagram 2 - Koraci prisutni kod *cross-docking*-a. [1]

2.2.2 PROCES IZLAZA ROBE IZ SKLADIŠTA

Proces se sastoji od dvije najvažnije skladišne operacije: komisioniranja i otpreme robe.

- Podrška naručivanju

Pregledom procesa ulaza robe u skladište i sastavnih operacija i aktivnosti valja prvobitno uzeti u obzir i element podrške naručivanju. Potražnja pokreće skladišni sustav tako da je podrška kupcima u njihovom naručivanju robe bitan element *pull* strategije. *Push-pull* strategija definira odnos proizvođača i potrošača, gdje kupci povlače potrebne proizvode i informacije, do proizvođači guraju proizvode prema potrošačima. Zbog velikog obujma ponude iz samostalnog asortimana bitno je imati elektronički sustav koji omogućuje detaljan, točan i sveobuhvatan pristup informacijama kako bi kupci imali potrebite informacije u pravom trenutku kod izrade narudžbe. Dodatna potpora kupcima sastoji se od odgovaranja na upite u vezi vremena isporuke, vremena dostupnosti trenutno ne raspoloživih proizvoda, pretvorbi šifri artikala, akcijskih ponuda, kontaktnih informacija na koje mogu slati narudžbe, informiranje o stanju narudžbe te ostalih podataka koje su kupcima potrebni.



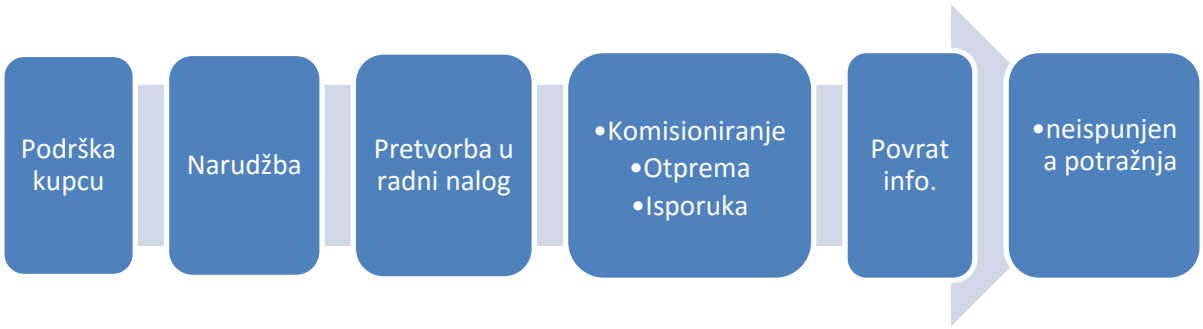
Slika 5 - Prikaz internet kataloga s cijenama i asortimanom. [1]

Slika 5 prikazuje katalog spojen na ERP sustav koji omogućuje kupcima pregled asortimana s cijenama i količinama na stanju, uz mogućnost izrade narudžbe i njenog slanja putem kataloga prema tvrtci na danju obradu. Ovakvi Internet sistemi omogućuju potpunu mobilnost kod pregleda i izrade narudžbe s svim potrebnim informacijama u vezi tržišne ponude koja sadrži asortiman matične tvrtke i asortiman ostalih proizvoda unutar određene industrije s svim karakteristikama proizvoda potrebnim za kritično odlučivanje.

- Obrada narudžbi

Obrada narudžbi je logistički proces koji sačinjava transformaciju zaprimljene narudžbe u radni nalog čime pokreće proces izlaza robe iz skladišta koji se sastoji od skladišnih operacija komisioniranja i otpreme, te popratnih aktivnosti, a završava fakturiranjem i isporukom naručene robe. Kupac predaje narudžbu dobavljaču, narudžba se transformira u radni nalog. Obrada narudžbi i tvorenje radnih naloga prethodi svaku operaciju komisioniranja.

Dijagram 3 ilustrira proces koji pokrene narudžba. Operacija komisioniranja počinje isključivo zaprimanjem narudžbe, zbog čega ju ne aktivira ni jedna druga aktivnost, tj. operacija.



Dijagram 3 - Proces obrade narudžbe. [1]

Zaprimanje narudžbe se može izvršiti s email-om, telefonom ili pomoću EDI-a (*electronic data interchange* / elektronička razmjena podataka). Obrada narudžbe često zahtijeva korištenje dodatnih informacija poput provjere cijena, dostupnosti zamjenskih proizvoda, vremena isporuke, te provjere kreditnosti kupca.

3) **Komisioniranje**

Nakon obrade narudžbe, tvori se radni nalog, na temelju kojega se pokreče komisioniranje. Komisioniranje može biti organizirano po kriterijima poput hitnosti narudžbe, vrijeme zaprimanja narudžbe, vremena isporuke, važnosti kupca i vrijednosti narudžbe [3]. Roba se slaže prema radnim nalozima koji se temelje na narudžbama kupaca. Nakon komisioniranja izvršeni nalozi se predaju na otpremu gdje se nalozi provjeravaju i pakiraju. Prilikom komisioniranja eventualne skladišne razlike se evidentiraju te prenose na otpremu na provjeru ili ispravak razlika.

4) **Otprema**

Nakon komisioniranja pripremljena roba se provjerava, čime se potvrđuju i zaključuju radni nalozi, pripremljena roba se provjerava i procesuira pakiranjem u palete ili kolete koje se i pozicioniraju na zonu za prikup isporuke te na kraju i odvoze na isporuku kupcu s ispisom potrebnih podataka za isporuku kupcu. Provjera komisioniranih zaliha uključuje njihovo skeniranje. Prilikom skeniranja mora se obratiti na pozornost dali je barkod prihvaćen jer je moguće mijenjanje barkodova od strane proizvođača, moguće je također ne skenirati proizvod a staviti ga u paket, može se isto tako skenirati krivi barkod zbog postojanja više njih te također moguće je da ERP sustav nema barkod unutar baze za neke zalihe, k tome u ERP sustavu može greškom biti uveden barkod artikla pod dugi. Operacija otpreme zahtijeva uporabu privremene zone (dijela skladišta s npr. zasebnim, za tu svrhu, regalom) gdje se privremeno skladišti komisionirana roba koja je pripremjena za isporuku a trenutno se ne isporučuje zbog razloga poput osobnog prikupa robe od strane kupca, ne pokrivanja osnovne vrijednosti narudžbe za mogućnost isporuke itd. Slijede dodatne aktivnosti:

- Isporuka

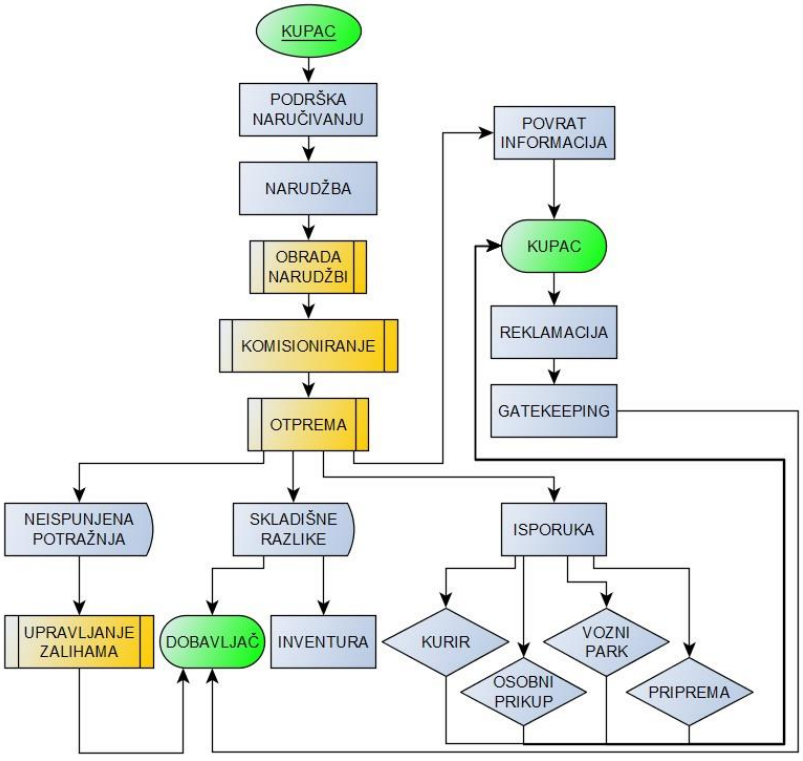
Nakon završetka otpreme vrši se priprema potrebne dokumentacije za isporuku. Usluge vršenja isporuke dostave se može koristiti preko *outsourcing*-a (usluge korištenja vanjskog operatera) ili pomoću vlastitih sredstava. Korištenjem kurirskih usluga papirološki zahtijeva otpremnicu, dok korištenje vlastitih sredstava za isporuku paketa iziskuje fakture i/ili otpremnice.

- Povrat informacija kupcu

Nakon otpreme, preostaje kupcu omogućiti pregled statusa narudžbe, te ga obavijestiti o eventualnim promjenama unutar narudžbe i vremena isporuke.

- Evidentiranje neispunjene potražnje

Informacije o potražnji koja nije bila ispunjena treba evidentirati jer su ti podaci bitni za potencijalno naručivanje vezano za upravljanje zaliha.

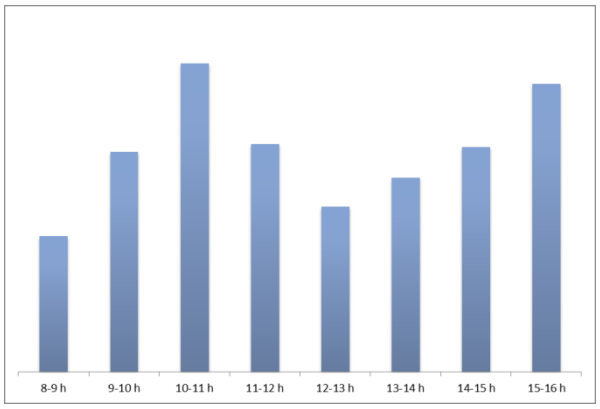


Dijagram 4 - Dijagram toka procesa izlaza robe iz skladišta. [1]

Pregledom glavna dva skladišna procesa i prisutnih u njima skladišnim operacijama i aktivnostima, valja uzeti u obzir i dodatne elemente koji su prisutni u skladišnom sustavu a ne pripadaju dvama glavnim procesima.

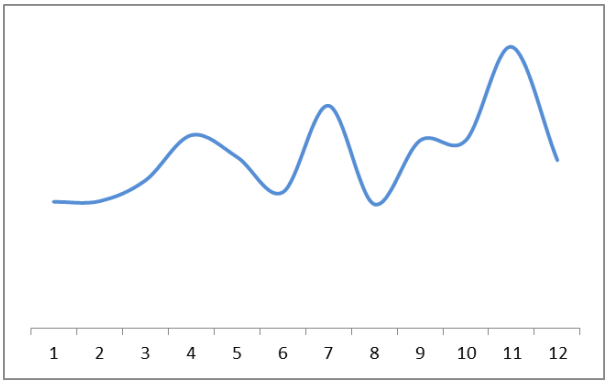
2.2.3 KVANTIFICIRANJE SKLADIŠNIH OPERACIJA

Kvantifikacija skladišnih operacija i procesa omogućuje izražavanje operacija kroz razne varijable poput vremena, troškova, količina, učinkovitosti i slično, kojima se daje pregled operacija radi danje kontrole, organizacije ili planiranja.



Dijagram 5 - Prosječna količina skladišnih operacija komisioniranja u danu. [1]

Dijagram 5 ilustrira obujam rada potrebnog za komisioniranje tokom dana, ovakav pregled pokazuje kritična vremena gdje treba konsolidirati radnu snagu radi maksimiziranja propusne moći skladišta. Također vršna vremena ukazuju i na najviše prikladne (optimalne) termine za vršenje operacije transporta.



Dijagram 6 - Izlazni promet robe u komadima unutar godine dana. [1]

Dijagram 6 ilustrira izlaz robe iz skladišta tokom jedne godine dana. Prikazana krivulja se sastoji od skladišnih operacija vezanih za skladišni proces izlaza robe iz skladišta. Kako je izlaz robe iz skladišta usko vezan za potražnju, tako ova krivulja isto ukazuje i na obujam procesa prijema robe u skladište koji se vrše po ukazanoj potrebi.

Ovakav Dijagram primarno pokazuje količinu rada koji se odvija unutar skladišta, ne uzimajući u obzir operacije poput transporta robe drugim subjektima. Pregledom oscilacija obujma posla po mjesecima unutar godine omogućuje planiranje dodatnih aktivnosti koje nisu redovni dio rada tvrtke poput rada na suprastrukturi skladišta (više o tome u 6.1), vršenje inventura i slično.

2.3 INVENTURA

Inventura služi za provjeru stanja zaliha. Stanje zaliha u skladištu se uspoređuje s stanjem unutar ERP sustava. Inventura se može raditi i nekoliko puta godišnje, no mora biti barem jednom napravljena. Rezultat inventure je popis skladišnih razlika. Nakon inventure eventualne razlike će se morati uskladiti s ERP sustavom. Inventura je bitan dio skladišnog upravljanja jer pokazuje efikasnost izvršenog rada kroz skladišne operacije tokom godine. Ona je ključan alat koji ocjenjuje kvalitetu izvršenog rada kroz određeno vrijeme putem postojećih skladišnih operacija. Temeljem loših rezultata inventure morati će se napraviti potrebite promjene unutar skladišnog sustava.

S inventurom se evidentira manjak i višak, pronalaze se također i krivo pozicionirani artikli, ako se provjera ne radi temeljito, nakon završetka inventure može se proglasiti manjkom zalihe koje su na stanju u skladištu ali na krivoj lokaciji. Prilikom provjere razlika, tj. izvršavanja inventure, obavezno treba zaključiti sve aktivne ulaze i izlaze.

Klasični pristup inventurama je da se skladište zatvori na neko vrijeme unutar kojeg se vremena obavi inventura. Ovakav pristup rezultira gubljenjem profita zbog zatvaranja skladišta.

Isplativiji način izvođenja inventure je ciklična inventura. Ona se vrši na način da se svaki dan napravi inventura malog dijela zaliha. Ovakav pristup inventuri može uzrokovati i cjelogodišnje prebrojavanje zaliha, što zavisi o broju radnika i količini zaliha. Prednosti ovakve inventure su da se svaki dan uloži malo vremena za prebrojavanje, tako da se skladište nikada ne mora zatvoriti što bi uzrokovalo smanjenjem prodaje.

Inventura se može vršiti po šiframa zaliha ili po lokacijama. Inventura po šiframa zaliha uzrokuje znatnu količinu rada zbog hodanja. Inventura po lokacijama je opće prihvaćen pristup, neke od teškoća prilikom takvog prebrojavanja su višestruke lokacije koje se tijekom inventure višestruko „obrađuju“ kao i zalihe s tih polica.

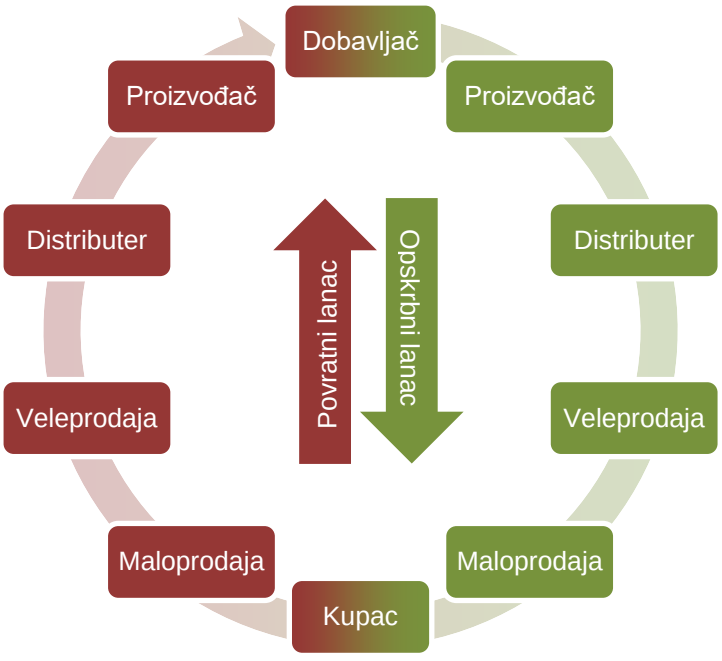
Prilikom inventure zalihe kojima je stanje nula nisu vidljive za provjeru po ERP sustavu, te se time njihovo prebrojavanje ni ne traži, zbog čega su jedino vidljive tijekom inventure po lokacijama gdje se češljaju regali po redu po lokacijama. Višak i manjak mogu biti prouzročen greškama u papirologiji ili greškama prilikom isporuka.

2.4 POVRAT ROBE

Povrat robe nazad niz opskrbi lanac može biti potrebno ostvariti zbog više razloga poput: ne mogućnost prodaje kupljene robe (ne mogućnost podmirivanja salda), krivog naručivanja, krive isporuke, odustajanja kupnje robe od strane treće osobe, povrat zbog reklamacije [1].

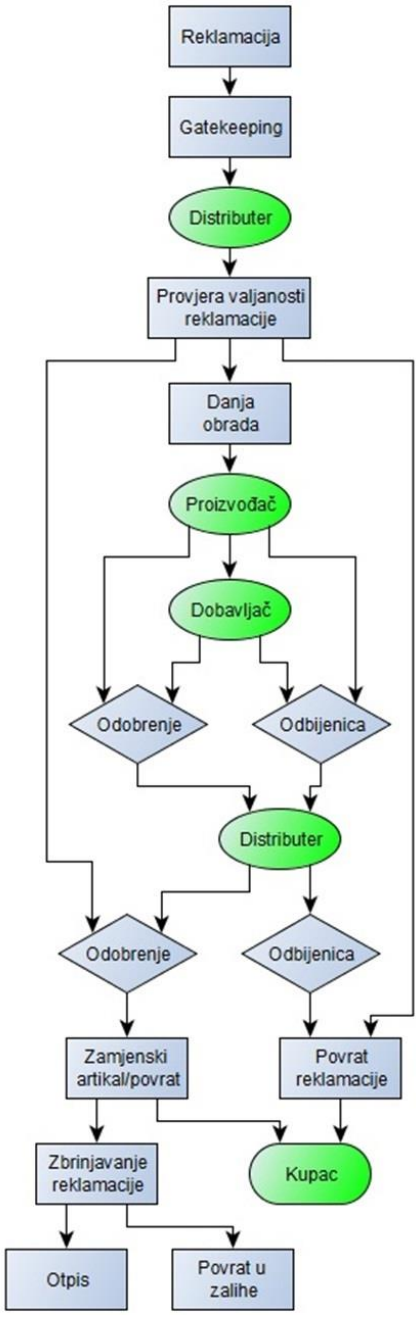
Reklamacije su proizvodi koji se vračaju nazad niz opskrbni lanac, samim time one su dio skladišnog sustava jer za njih postoji zasebna skladišna operacija koja se bavi njihovom obradom i zbrinjavanjem. Za razliku od obrade narudžbi koja se bavi izlazom zaliha iz skladišnog sustava, reklamacije spadaju pod povrate koji se vračaju u skladišni sustav, tj. distribucijski kanal.

Reklamacije proizvoda čine ne zanemariv trošak poslovanja jer se radi o povratu zaliha u opskrbni lanac gdje jedan od (ili više) subjekata mora snositi trošak povrata sredstava u slučaju da je reklamacija odobrena. Njihovo zbrinjavanje zahtijeva primarno provjeru valjanosti reklamacije i dali se je vratila u izvorni kanal (*gatekeeping*) nakon čega se reklamacije skladište u predviđeni dio skladišta za reklamacije do danje obrade i krajnjeg razrješenja. Zbog sve veće otvorenosti tržišta tokom utjecaja globalizacije te sve veće ponude proizvođači se nalaze u često sekundarnoj poziciji naspram kupca kod pitanja reklamacija [3]. Zbog otežanog probijanja na tržište i zadržavanja svoje pozicije tako preuzimaju reklamacije koje često ne spadaju pod jamstvo zbog nepridržavanja ugovorenih uvjeta. Osim reklamacija koje su utemeljene, također mogu biti i odobrene dogovorom između proizvođača i distributera temeljem poslovne strategije. Prilikom zaprimanja reklamacije dobavljač vrši osnovni pregled proizvoda gdje utvrđuje dali je proizvod pripada u taj kanal, te dali se vide znakovi neprimjerene uporabe. Nakon Zaprimanja reklamacije u povratni sustav, ona se najčešće šalje nazad na obradu proizvođaču, s time da i dobavljač može odobriti reklamaciju zbog strateških razlog. Kupac zaprima u međuvremenu potvrdu da mu je reklamacija zaprimljena.



Dijagram 7 - Opskrbni i povratni lanac. [1]

Nakon odobrenja reklamacije najčešće se kupcu ustupa zamjenski proizvod, dok distributer zbrinjava reklamirani proizvod. U velikim slučajevima zbog dislociranosti proizvođača i distributera reklamacije se odlažu na reciklažne centre ili otpade, tj. vrši im se otpis, bez pokušaja povrata vrijednosti reklamiranog proizvoda. Tijekom obrade reklamacije ona se mora zbrinuti unutar skladišta određenog za reklamacije. Također je moguće da je reklamacija prihvaćena a da se radi o ispravnom proizvodu, u kom slučaju se takav proizvod može vratiti u zalihe distributera uz eventualnu obradu pakiranja ako je to potrebno. Najčešći uzrok ovakvog povrata je nerazumijevanje korištenja proizvoda od strane kupca/korisnika. Slika 6 pokazuje proces obrade reklamacije uzet iz stvarnog primjera [1]. Vidljivo je po dijagramu dijagramu toka obrade reklamacija da se proces obrade reklamacije vrši zajedničkim djelovanjem dobavljača, proizvođača i distributera.



Slika 6 - Dijagram toka obrade reklamacije unutar opskrbnog lanca. [1]

2.5 LJUDSKI POTENCIJALI

Bitna varijabla koja utječe na kvalitetu odrade skladišnih operacija je ljudski faktor čovjeka. Rezultat inventure može ukazivati na eventualne greške unutar sustava ali i na eventualne probleme vezane za ljudske resurse. Stvaranje manjka može biti rezultat grešaka ali i namjernih propusta na razini ljudskih potencijala [1].

Utjecaj ljudskih potencijala na efikasnost izvođenja skladišnih operacija je također bitna varijabla koja se treba pratiti zbog vrednovanja kako individualne produktivnosti, tako cjelovite skladišne operacije. Kvaliteta obavljenog rada utječe na vrijeme trajanja skladišnih operacija, krivo komisionirane zaliha rezultiraju dodatnim vremenom rada koji se treba uložiti u ispravljanje grešaka, također greške kod pohrane robe rezultiraju zametnutim zalihama koje se ne mogu prodati dok se ne lociraju. Dakako, ni količina obrađenog posla nije ista od radnika do radnika.

Premda ovaj faktor nije direktno uzet u obzir kod kvantitativnih analiza on je zaista značajan na operativnoj razini jer može rezultirati povećanjem troškova.

Varijable poput vremena hodanja, pretrage regala, prikupa zaliha s regala i vremena pripreme za komisioniranje je različito od radnika do radnika.

Provjeravanje razlika tijekom operacije prijema (tj. rezultata procesa pohrane) i otpreme omogućuje provjeru rada koja je bitna radi kontroliranja stvaranja razlika.

2.6 SKLADIŠNA OPREMA

Nužan i bitan suprastrukturni element su skladišni regali. Premda postoji mnogo više samih izvedbi regala navedene vrste regala imaju praktičnu primjenu kod veleprodajnih skladišta. Skladišni paletni regali te regali lake izvedbe omogućavaju racionalno iskorištenje prostorija skladišnog objekta i služe za skladištenje paletizirane i ne paletizirane robe. Kako vrsta skladišta tako i suprastruktura skladišta bitno utječe na izvođenje skladišnih operacija a time i vršenje skladišnog upravljanja. Razumijevanje postojećih karakteristika regala i karakteristike robe koja se skladišti služi svrsi odabira vrste i količine izvedbi regala potrebnih za funkcioniranje skladušnog sustava.

Ponuda skladišnih polica, regala i karusela je široka te pokriva praktički sve tipove skladišnih jedinica (standardne i nestandardne palete, *box* palete te razna specifična rješenja).

Regali lake izvedbe su dosta zastupljeni u maloprodajnim i veleprodajnim tvrtkama. Radi se uglavnom o visini do dva i pol metra samog regala koju mogu ali i ne moraju biti etažirani u jedan zajednički suprastrukturni element.

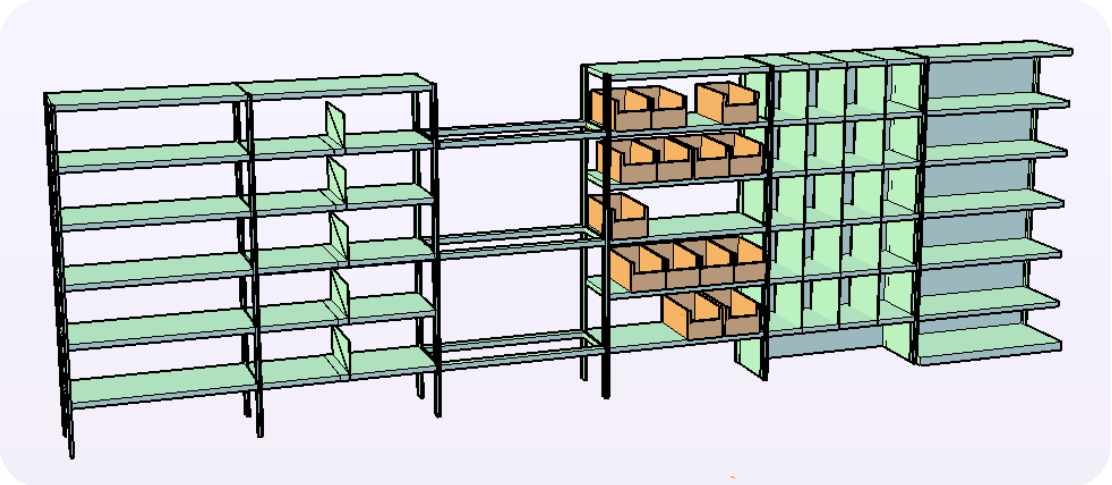
Klasični paletni regali predstavljaju univerzalni sistem skladištenja s direktnim pristupom svakoj paleti. Višestruko povećavaju prostor predviđen za skladištenje i lako se prilagođavaju paletama svih veličina i masa. Klasični paletni regali su najbolje rješenje za skladišta u kojima se čuva veliki broj različitih artikala na paletama. S obzirom da se komisioniranje robe često obavlja u samim prolazima česta je i pojava da se u regale montiraju grede, nosači polica za ručno odlaganje i pripremanje robe. Raspored i visina stalaža ograničeni su isključivo karakteristikama viljuškara, paletama koje se skladište i gabaritima objekata.

Ulazni i provozni skladišni regali su idealno rešenje za skladištenje homogene robe (istih karakteristika) kod koje “rotacija” (ulaz - izlaz) nije dominantan faktor. Konstrukcija se sastoji od niza vertikalnih elemenata-okvira koji formiraju unutrašnje koridore za odlaganje tereta i horizontalnih nosećih elemenata - šina na koje se odlažu palete. Ovakvo tehničko rešenje omogućava maksimalno iskorištenje skladišnog prostora.

Protočni skladišni regali pogoduju za skladištenje robe istih karakteristika kod koje je “rotacija” (ulaz - izlaz) dominantan faktor. Konstrukcija se sastoji od standardnih vertikalnih elemenata-okvira, horizontalnih nosača - greda i setova valjaka koji sa njima formiraju koridore za palete. Sami koridori su nagnuti za određeni kut u odnosu na pod tako da omogućuju paletama da se lagano kotrljaju preko valjaka od ulaza prema izlazu regala. Ovakvo rešenje omogućava maksimalno iskorištenje skladišnog prostora.

2.6.1 REGALI LAKE IZVEDBE

Namijenjeni su za uporabu u priručnim skladištima, trgovinama tehničke robe, obrtničkim radionicama, kancelarijama i javnim prostorima kao što su knjižnice, općine, sudovi, registri, zdravstvene ustanove, arhivi itd [8]. Zbog jednostavnog postavljanja i prilagodljivosti pri raspoređivanju regali lake izvedbe rabe brojni trgovci.

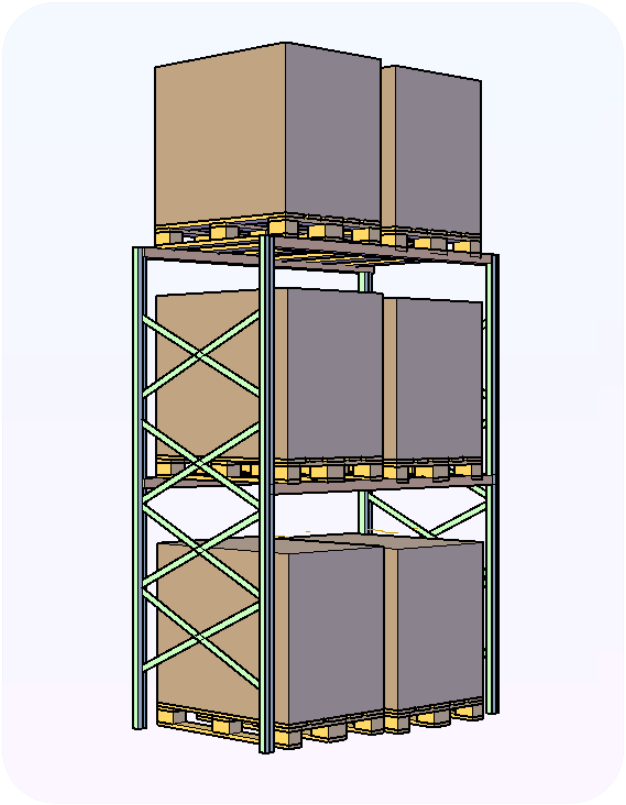


Slika 7 - Različite izvedbe regala lake izvedbe. [1]

Veliki broj normiranih dimenzija skladišnih regala omogućava maksimalno prilagođavanje prostoru u širini i u dubini. Na raspolaganju je širok izbor dodataka koji skladišne regale određuju za specifičnu svrhu uporabe, a konačni izgled daje im cinčana ili obojena površinska obrada. Nosivost poličnih regala prilagodljiva je masi proizvoda, a u slučaju potrebe za većom nosivošću moguće ih je ojačati.

2.6.2 PALETNI REGALI DUBINE PALETE

Najčešće upotrebljavani regali za skladištenje paleta. Nude najviše selektivnosti i fleksibilnosti ali najmanje iskorištenja skladišnog prostora. Omogućavaju neposredan pristup paletama te visok stupanj prilagodljivosti s obzirom na veličinu, oblik i masu paleta, a uporabom dodatne opreme regala možemo skladištiti i robu koja nije na paletama [8].



Slika 8 - Paletni regali dubine palete. [1]

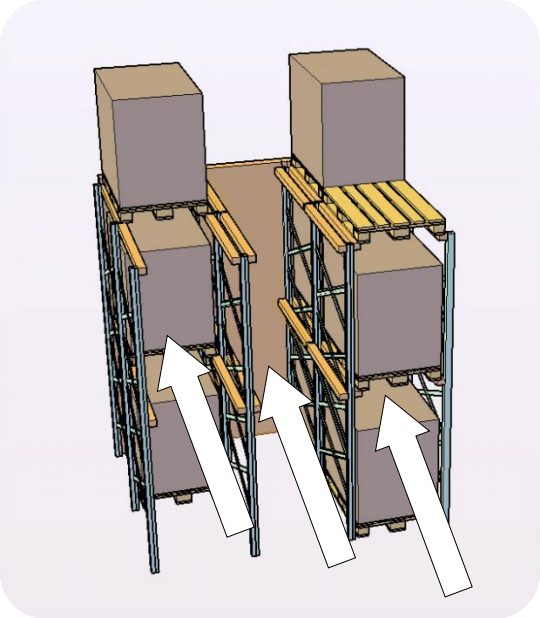
Ovako skladištene palete su uvijek dostupne no na štetu iskoristivosti skladišnog prostora, tj. manja je gustoća skladištenja paleta, upotrebljava se više prostora za manje pozicija kako regali dubine jedne palete iziskuju znatno više među regalnih prolaza. Najčešća im je upotreba kod proizvoda s malim vremenom skladištenja, za koje je potrebna najbolja dostupnost.

2.6.3 PROVOZNI PALETNI REGALI

Idealni za skladištenje velike količine robe iste vrste. Omogućavaju skladištenje velikih količina jednake odnosno manje raznovrsne robe na maloj površini. Tim načinom čuvanja robe u dubini je namješteno više paleta jedna za drugom. Ovakav sistem pogodan je za robu koja se može skladištiti na paletama jedna iza druge ili jedna povrh druge, te također i kada je potreban veći pristup u odnosu na slaganje u blokovima. Palete su složene po principu FILO *(first-in, last-out* / prvi unutra, zadnji van*)* na nosačima montiranim na obje strane provoznog kanala. To znači da se pojedinim paletama ne može pristupiti izravno, već jednoj po jednoj s prednje strane regala. Ovakav sistem skladištenja pogoduje robi koji imaju duži životni vijek i koja ne iziskuje trenutnu dostupnost [1,8].

- **Jednostrani ulazni regali**

Provozni ulazni regali Dozvoljavaju manipulacijskom sredstvu (viličar) da uđe u regal, tj. regalni skladišni prostor, da bi ili uveli ili izvezli skladišni teret. Dubina regala je određena skladišnim prostorom unutar kojeg se regali nalaze. Ovakav sistem skladištenja robe je izložen većem broju oštećenja nego ostali sistemi, tako da je vrlo važno da se radi o snažnoj konstrukciji s kvalitetnim integritetom. Ovakva pohrana robe je idealna za robu koja se hladi i zamrzava, selektivnost je umanjena radi povećanja gustoće skladištenja. Zahtijeva srednju količina prolaza [8].



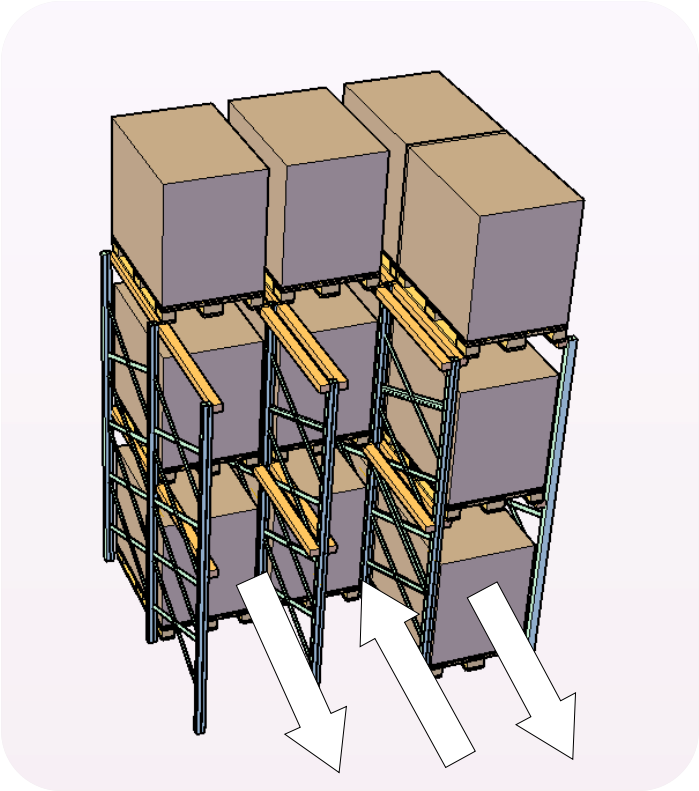
Slika 9 - Ulazni paletni regali. [1]

Prednosti [8]:

- Pogodno za robu koja se skladišti u hladnim prostorima koji su vrlo mali a kod kojih se iziskuje maksimalna prostorna iskoristivost;
- Pogodno za sezonsku robu koja ima veliku brzinu izlaska iz inventara;
- Pogodno za veliku količinu istovrsne robe koja se može skladištiti po FILO sistemu.

- **Dvostrani ulazni regali**

Omogućavaju manipulacijskom sredstvu (viličar) da uđe s obje strane regala radi uvoza ili izvoza tereta. Teret se uvozi na visini regala na koju će se raspremati, te se nakon odlaganja oslanja na poprečne greda. Ovakav sistem vrši baratanje robom po sistemu FIFO *(first-in, first-out* / prvi unutra, prvi van*)*, tj. iz regala se izvlači prva dostupna paleta [8].



Slika 10 - Prikaz provoznih paletnih regala. [1]

Prednosti [8]:

- Pogodno za robu koja se skladišti u hladnim prostorima koji su vrlo mali a kod kojih se iziskuje maksimalna prostorna iskoristivost;
- Pogodno za sezonsku robu koja ima veliku brzinu izlaska iz inventara;
- Pogodno za veliku količinu istovrsne robe koja se može skladištiti po FILO sistemu.

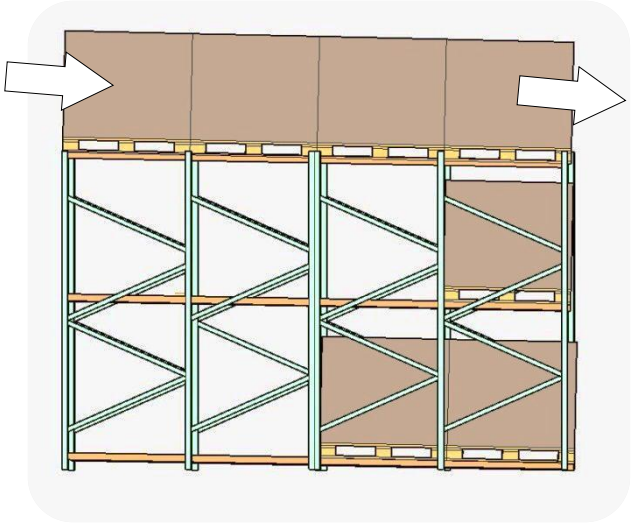
2.6.4 PROTOČNI PALETNI REGALI

Protočni regali maju visoki stupanj gustoće skladištenja paleta, iziskuje jako malo prolaza, princip slaganja paleta i njihove rotacije na regalima je FIFO *(first-in, first-out)*, što pogoduje robi koja je vremenski osjetljiva. Glavna karakteristika protočnih regala je da od svih sistema regalnog skladištenja paletiziranih proizvoda ima najveću gustoću / iskoristivost skladištenja skladišnog prostora. Količina paleta koja se može skladištiti u nekom objektu je ograničena samo dimenzijama objekta, jer ovaj sistem iziskuje vrlo malo prolaza [8].

- **Gravitacijski regali**

Gravitacijski regali sastoje se od dva elementa: statične strukture regala i dinamičkih protočnih vodilica.

Protočne vodilice se sastoje od sistema valjaka postavljenih na nagibu uz cijelu duljinu regala. Takav sistem omogućuje da se teret giba pomoću utjecaja gravitacije s kraja utovara na kraj istovara po navedenim pomičnim protočnim trakama / redovima. Svaki pomični red sadržava mehanizme za kontrolu brzine kretanja tereta (kočnice) tako da lagano usporava brzinu kretanja tereta unutar konvejera. Kako se na istovarnom kraju regala teret skine sa konvejera, tako se ostali tereti iza njega polagano spuštaju do istovarnog dijela, jedan po jedan [8].



Slika 11 - Prikaz gravitacijskog paletnog regala. [1]

Prednosti [8]:

- FIFO sistem skladištenja robe, pogodno za vremenski osjetljivu robu;
- Velika iskoristivost skladišnog prostora;
- Automatska rotacija tereta na regalima, što uzrokuje manju uporabu i količinu manipulacijskih sredstava za obavljanje posla, te i manje vremena za skladišne operacije;
- Eliminira potrebu za preslagivanje tereta;
- Potrebna jedino dva prolaza za utovar i istovar robe s regala;
- Jednostavna funkcija skladištenja, veće efikasnost radne snage.

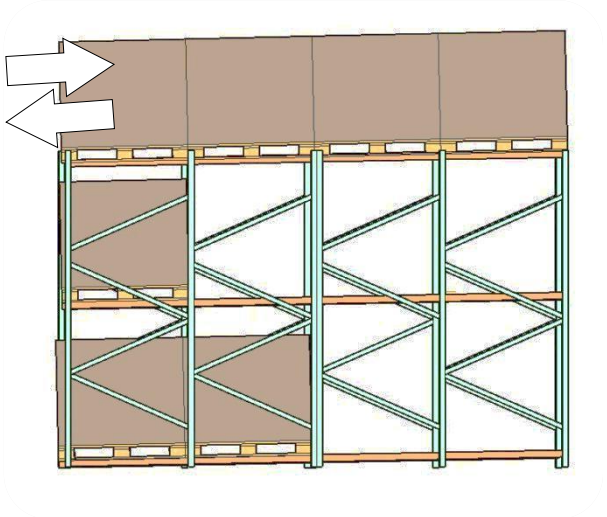
2.6.5 TELESKOPSKI REGALI

Teleskopski regal je pogodan za robu u rasutom stanju koja se može skladištiti na paletama po principu FILO *(first-in, last-out)*. Skladištenje, ulaganje i uklanjanje paleta s regala se vrši isključivo s jedne strane [8].

Teret se slaže s viličarom na naklonjeni dio konvejera regala. Svaka paleta koja je na regalu se gura s paletom koja se ulaže na regal pomoću viličara. Kada se teret skida s regala, viličar uzima prvu dostupnu paletu, što automatski uzrokuje da se palete koje se nalaze iza one koja se izvlači van, polako spuštaju prema naklonjenoj strani regala.

Jedna za drugom, do deset paleta može se ugurati u protočne kanale i kad jednu paletu pokupi vodilica, ostatak ide automatski naprijed kontroliranom brzinom. Ovakvim sistemom, pojedinačnim paletama koje se nalaze u pozadini regala ne može se pristupiti izravno.

Teleskopski regal također se može koristiti kako bi se osigurao dodatni prostor za skladištenje u inače neiskorištenim područjima, kao što su poprečni prostori ili rampe za utovar. Kada je iskorištenost potpuna, moguće je postići vrlo visokog postotka popunjenosti prostora, u odnosu na npr. prolazne regale.



Slika 12 - Prikaz teleskopskog paletnog regala. [1]

Prednosti [8]:

- FILO sistem skladištenja robe, pogodno za robu u rasutom stanju;
- Velika iskoristivost skladišnog prostora;
- Automatska rotacija tereta na regalima, manja uporabu i količina manipulacijskih sredstava za obavljanje posla (manje od gravitacijskog sistema);
- Potreban jedino jedan prolaza za utovar i istovar robe s regala;
- Jednostavna funkcija skladištenja, veće efikasnost radne snage;
- 90% iskoristivost skladišta za razliku od klasičnih sistema.

3. ZNAČAJKE ROBE I SKLADIŠTENJE

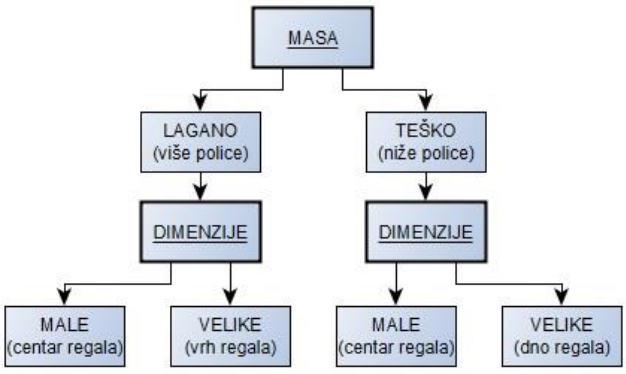
Zalihe postoje unutar cijelog opskrbnog lanca zbog dislociranosti između ponude i potražnje. Opskrbni lanac uključuje dobavljače, proizvođače, distributere i krajnje kupce. Svaki od tih entiteta je međusobno udaljen zbog čega se često potražnja zadovoljava preko velikih prostornih i vremenskih udaljenosti. Etalonski gledano, prostorna i vremenska udaljenost se smanjuje kako se karike lanca približuju konačnom kupcu. Zalihe zadovoljavaju buduću potražnju. Uloga zaliha je također da osigura zadovoljenje potražnje prilikom osciliranja potražnje. Uloga zaliha je i da optimiziraju troškove koji su vezani za trgovačko poduzeće.

Gledano s razine fizičkog uskladištenja zaliha, karakteristike robe i karakteristike skladišne suprastrukture su značajan faktor koji valja uzeti u obzir prilikom organizacije uskladištenja. S obzirom na problematiku pojedinačne vrijednosti obrtaja robe (prikazano vizualno toplinskom mapom suprastrukture) te fizičkih karakteristika robe, biti će odrađeni načini uskladištenja koji robu zoniraju, grupiraju, kategoriziraju tako da se što lakše i brže komisionira (pod poglavlje 2.2).

Omogućavanje kompjuterizacije skladišnih operacija vezanih za manipulaciju robe postiže se korištenjem barkodova artikala koji služe kao glavna vrijednost za prepoznavanje ostalih karakteristika zaliha unutar ERP sustava koji služe za pojednostavljenje rada, osiguravanje veće točnosti i smanjenje vremena manipulacije.

3.1 KARAKTERISTIKE ROBE

Iskoristivost regalnih prostora je jedan od mikro elemenata koji znatno utječu na iskoristivost skladišnog prostora. Govoreći o ne paletiziranoj robi potrebno je uzeti u obzir da su fizičke karakteristike robe bitne te da se temeljem tih vrijednosti predefiniraju njihovi načini uskladištenja radi optimizacije skladišnog sustava i prostora.



Slika 13 – Opći prikaz utjecaja karakteristika robe kod pozicioniranja na regale. [1]

Slika 13 prikazuje opći prikaz, tj. pristup odabiru pozicioniranja robe na regale prema njihovim dvjema karakteristikama; dimenzijama i masi. Teža roba se pozicionira na nižim dijelovima regala dok lakša na višim, zbog lakoće manipulacije i osiguravanja bolje sigurnosti tijekom rada. Nadalje dimenzije robe utječu na visinu regala u s aspekta mogućnosti pregleda robe jer je roba manjih dimenzija teže raspoznatljiva neko ona s većim dimenzijama.

Položajem zaliha na polici određuje se raspoloživost, tj. podobnost, ispunjenja preostalog regalnog prostora s obzirom na dimenzije zalihe. Općenito pravilo slaganja zaliha na regal je da se iste zalihe prvo slažu u dubinu regala pa prema visini a tek onda u širinu regala.

Odnos karakteristika robe i karakteristika regala je bitan odnos koji treba raspoznati i definirati jer je skladišna suprastruktura projektirana značkama robe koja će biti držana na stanju tako da sama pohrana robe na regale mora biti vršena prema tom odnosu radi boljeg iskorištenja suprastrukture i smanjenja vremena prikupa i pohrane robe.

Karakteristike proizvoda – prilikom faze pohrane zaliha valja uzeti u obzir fazu komisioniranja za koju je ključno vrijeme prikupa zaliha tijekom slaganja radnih naloga. Nepraktično i nesmisleno složene zalihe smanjuju vrijeme prikupa zbog više vremena utrošenog na pretragu regala za traženom stavkom s naloga. Elementi koji utječu na pozicioniranje su [1]:

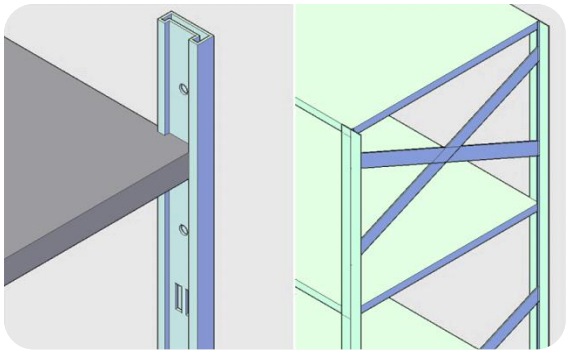
1) Masa – masa skladišne jedinice je karakteristika koja se uzima u obzir kod odlučivanja pozicioniranja zaliha u odnosu na zonu otpreme te također kod pozicioniranja zaliha na određenu visinu regala radi sigurnosnih razloga. Lagane zalihe se uglavnom raspremaju na višu razinu regala dok teže na nižu, što je bitno zbog smanjenja napora pri prikupu robe i radi osiguravanja zaštite radnika u skladišnom prostoru;
2) Dimenzije – dimenzija proizvoda utječu na poziciju zaliha s obzirom na visinu regala u smislu da se sitna roba mora okrupniti da bi se mogla iskoristivo skladištiti;
3) Količine – određenih vrsta zaliha ima više no ostalih, tu se radi najčešće o artiklima s velikim obrtajem. Tako da samim time količina zaliha takvih proizvoda će biti veća no od ostalih zaliha, čime će zahtijevati više skladišnog prostora;
4) Oznake zaliha – skladišne jedinice zaliha moraju biti označene svojom šifrom zbog definiranja i upravljanja. Bitno je da te oznake zaliha gledaju prema prolazima radi njihovog lakšeg prepoznavanja tijekom komisioniranja;
5) Posebne karakteristike – zalihe mogu biti raznih oblika (npr. okrupnjene u vrećicama) te agregatnih stanja što utječe na njihovu pozicioniranost unutar skladišta;
6) Kombinacija karakteristika – kombinacija gore navedenih karakteristika također utječe na mjesto uskladištenja zaliha. Primjer tome je da se sitna roba skladišti na regale dostupne radnicima bez dodatnih skladišnih pomagala, dok nadalje masa tih zaliha određuje hoće li biti raspremljene u skladišni prostor bliži ili udaljeniji otpremnoj zoni. Još jedan primjer je da se krupne zalihe ne miješaju s sitnom na regalima radi međusobne neskladnosti, pogotovo ako se radi o krupnim a teškim zalihama i sitnim te laganim.

Karakteristike regala – regali omogućavaju racionalno iskorištenje skladišnih prostorija i služe za skladištenje paletizirane i ne paletizirane robe. Široka paleta normiranih dimenzija skladišnih regala omogućava maksimalno prilagođavanje prostoru u visini, širini i u dubini. Na raspolaganju postoji i širok izbor dodataka koji skladišne regale određuju za specifičnu svrhu uporabe. Nosivost polica je također bitan faktor koji je vezan za karakteristike zaliha.

Glavne karakteristike regala:

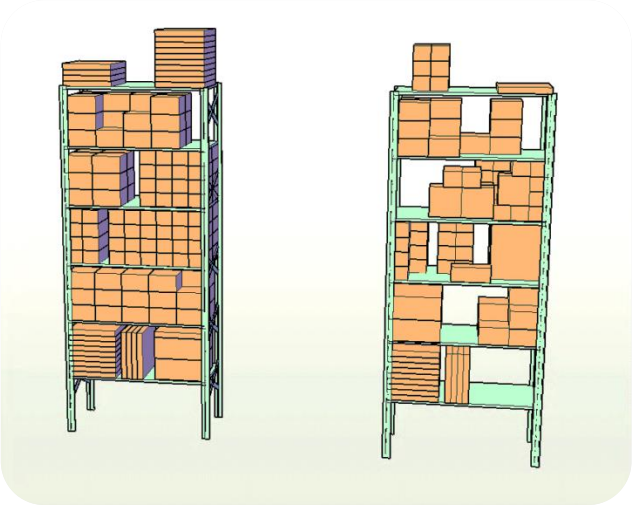
a) Dimenzije – što su veće police to radniku treba više vremena da ih pretraži ako je zaliha manjih dimenzija u odnosu na razmak ispuna regala;
b) Nosivost – bitna je kod težih zaliha;
c) Namjena – bitna je kod zaliha s netipičnim karakteristikama.

Slika 14 ilustrira različitost izvedbi regala lake izvedbe, određene konstrukcije omogućavaju postizanje veće nosivosti, dok se istovremeno mijenjaju druge karakteristike poput načina slaganja regala i međusobnog povezivanja konzola regala.



Slika 14 - Prikaz izvedbe police i regala. [1]

Način pohrane robe na regale tj. mikro upravljanje robom tijekom njene pohrane, ima osjetne posljedice kod vremena operacije komisioniranja. Slika 15 ilustrira kako neorganizirano pohranjena roba na regalnom prostoru usporava vrijeme prikupa jer povećava vrijeme pretrage za proizvodom na regalu. Također, ako je visok broj zaliha te su skladišni kapaciteti popunjeni, u slučaju neorganiziranog regalnog prostora u tom slučaju će biti veoma sporo komisioniranje.



Slika 15 – Prikaz organiziranih i neorganiziranih zaliha na regalima. [1]

Postoji široka ponuda različitih vrsti regala koji se mogu koristiti za skladištenje robe. Važno je uzeti u obzir karakteristike robe koje će se skladištiti, te prema tome a i osobnom kapitalu odabrati prikladne regale s kojima će se moći postići maksimalna iskoristivost skladišnog prostora.

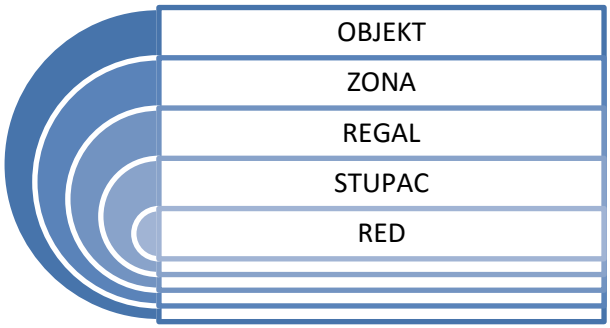
3.2 LOKACIJE

U skladišnim sustavima bez potpore WMS-a način pohrane rone na regale je temeljem zapisa njihovih lokacija. One se određuju na temelju više kriterija koje su bitne za rad s zalihama specifičnim za određeni skladišni sustav.

Bitno pravilo kod dodjeljivanja lokacija zalihama (sustavi bez WMS-a) je da ih se dodjeljuje u što manjem broju (skladište kojemu je kapacitet iskorišten uzrokuje više lokacija za proizvode, razlog tome je popunjenost regala što utječe na proširenje lokacija kod pohrane novih proizvoda) [1,13]. Manji broj lokacija omogućuje brže komisioniranje radi lakšeg lociranja zaliha, time povećavajući produktivnost. Kod WMS sustava software vrši proračun najmanje potrebnih lokacija za komisioniranje potrebnih količina robe s naloga bez obzira koliko ima lokacija po stavci naloga tj. jednom proizvodu s naloga. Kako WMS sustav nema sam zapisuje lokacije prilikom komisioniranja, on ih također i optimizira prema potrebnim količinama za stavke s naloga tako da radnik koji komisionira robu izvrši optimalni put prikupa robe [14]. Dakako mana tehnike skladištenja robe s što manje lokacija je ta što ima manju iskoristivost skladišnog prostora od kaotičnih sustava. Dok je kod kaotičnih sustava bolja iskoristivost skladišnog prostora, uglavnom se radi o većem broju lokacija te manjim količinama robe po lokacijama što može uzrokovati i veći put prikupa prilikom komisioniranja.

Pozitivna strana rasporeda skladištenja zaliha određena pravilima je da omogućuje u slučaju greške retroaktivno pronalaženje artikala logikom pohrane (suzbijanje mogućih lokacija, eliminiranje regala, smanjenje mogućih rezultata). Kod promjene lokacija, treba provjeriti trenutno stanje u ERP da se potvrdi da je sva količina artikla preuzeta.

Dijagram 8 pokazuje pristup pisanja lokacije regala za pohranu robe s obzirom na veličinu elemenata skladišnog sustava. Logika pisanja lokacija je da se kreče od većeg objekta i ide prema manjemu.



Dijagram 8 - Pravilo izrade lokacija. [1]

Osim veličine fizičkih elemenata skladišnog sustava drugi bitan element je opći smjer kretanja komisioniranja koji se određuje u projektiranju suprastrukture i iskazuje u dodjeljivanju redoslijeda lokacija suprastrukturi.

Označavanje regala – vrši se tako da se odredi protok kretanja kroz skladište te se prema njemu označavaju regali. Protok kretanja se planira kod projektiranja suprastrukture skladišta, mora biti izveden na optimalan način s obzirom na karakteristike skladišta, vrstu robe i regala koji će se koristiti.

Ispod prikazani dijagrami ilustriraju smjer komisioniranja prema lokacijama uskladištene robe gdje svaka stavka radnog naloga ima svoju specifičnu lokaciju. Temeljem tih lokacija obavlja se rad komisioniranja u što kraćem vremenu prema redoslijedu lokacija.

Dijagram 9 pokazuje kako je kod WMS sustava vidljivo da je u slučaju nedostupnosti potpune količine određene robe na pojedinoj lokaciji moguća nadopuna količine s druge lokacije no s uvažavanjem potrebe prikupa druge robe ako se nalazi u među lokaciji. U ovom slučaju WMS će podijeliti stavke naloga po lokacijma i raspoloživim količinama radi postizanja bolje optimizacije puta prikupa.

Dijagram 10 pokazuje kako komisioniranje bez potpore WMS sustava iziskuje obradu svake stavke radnog naloga u cijelosti prije prelaska na drugu stavku (prikup svih količina jedne stavke s više lokacija), što je činjenica zbog nepraktičnosti prikupa robe s različitih udaljenih lokacija na način da se u više navrata evidentiraju manje prikupljene količine zbog važnosti slijeđenja optimalne rute prikupa robe (obraditi pažnju na robu A s dijagrama).



Dijagram 9 - Primjer komisioniranja pomoću lokacija putem WMS sustava. [1]



Dijagram 10 - Primjer komisioniranja pomoću lokacija bez WMS sustava. [1]

Utjecaj WMS-a na odabir lokacije - kaotična pohrana zaliha podrazumijeva da se zalihe ne odlažu na unaprijed određene lokacije. U ovakvom sistemu najčešće se zalihe raspremaju logikom najbliže lokacije radi brže pohrane. Pristupačnost lokacije se određuje putem prijeđenim kroz prolaze između dvije točke, a ne međusobna udaljenost između dvije točke. Kaotična pohrana može sadržavati tehnike grupiranja ili zoniranja. Na primjer ako se radi o etažnom skladištu, lakši dio robe bi se raspremao na gornjim etažama dok teži na donjim, bez obzira što se i dalje unutar etaža zalihe raspremaju na kaotičan način. U ovom slučaju razlog pohrane lakših zaliha na gornje etaže, s težih na donje je mješavina strukturalnog integriteta konstrukcije integrala i pojednostavljenja komisioniranja i odvoza zaliha do zone otpreme s obzirom na zahtjevniji put koji se mora prijeći.

Označavanje ćelija konzole regala – lokacija ćelija se sastoji od dvije varijable koje su stupac i red regala (stupac i red). Nakon pregleda elementa lokacija na pohranu robe, sljedeći bitan element su zone koje su prisutne kako u cjelokupnom skladišnom objektu tako i u regalnoj suprastrukturi.

3.3 BARKODOVI

Barkodovi služe za elektroničku identifikaciju robe. Njihova uporaba olakšava, ubrzava i osigurava točnost obrade robe prilikom operacija prijema, pohrane, komisioniranja i otpreme. Postoje različite vrste barkodova, dolje navedeni barkodovi su bitni za skladišno trgovačku industriju. Barkodovi moraju biti jedinstveni identifikator skladišne jedinice koju predstavlja. Uporaba barkodova smanjuje sva vremena Barkodovi imaju važnu primjenu u operativnom pogledu zbog pozitivnog utjecaja kod manipulacije robe [1,15].

Linearni brojčani barkodovi [15]:

- *UPC*[1] - Koriste se radi označavanja i skeniranja potrošačkih zaliha u tvrtkama, zastupljeni su u Americi. Postoje dvije varijacije:UPC-A (12 znakova), UPC-E (6 znakova).
- *EAN*[2] - Slični UPC barkodovima s istom primjenom, glavna im je razlika geografska primjena, zastupljeni su u Europi. Varijacije**:** EAN-13 (najzastupljeniji), EAN-8, JAN-13, ISBN, ISSN.

Linearni znakovno brojčani barkodovi [15]:

- Kod 39 - Uporaba im je označavanje proizvoda iz uglavnom automotivne industrije. Omogućavaju uporabu slova i brojeva.
- Kod 128 - Kompaktni barkodovi koji omogućavaju spremanje velikog broja različitih informacija. Uporaba im je u logistici i transportu (opskrbni lanci). Podržavaju bilo koji znak iz ASCII-a.
- *ITF*[3] - Uporaba im je označavanje pakirnih materijala na globalnoj razini zbog tolerancija prema različitim printerima i podlogama. ITF barkodovi kodiraju 14 znamenki i upotrebljavaju puni ASCII kod.
- Kod 93 - Primjena im je unutar logistike, služe za označavanje elektronike. Podržava puni ASCII kod, no za razliku od koda 39 kod je zbijeniji što omogućuje njegovo skraćenje i manje zauzimanje prostora na zalihama.

2D barkodovi [15]:

- *DATAMATRIX*- Koriste se radi označavanja malih zaliha. Velika im je brzina čitanja i imaju visoku toleranciju na pogrešku prilikom očitavanja koda.
- *PDF417*[4] - Omogućuju spremanje velikih količina podataka, poput fotografija, potpisa, tekstova, brojeva itd.
- *MSI PLESSEY* - Koriste se kod označavanja lokacija na regalima.

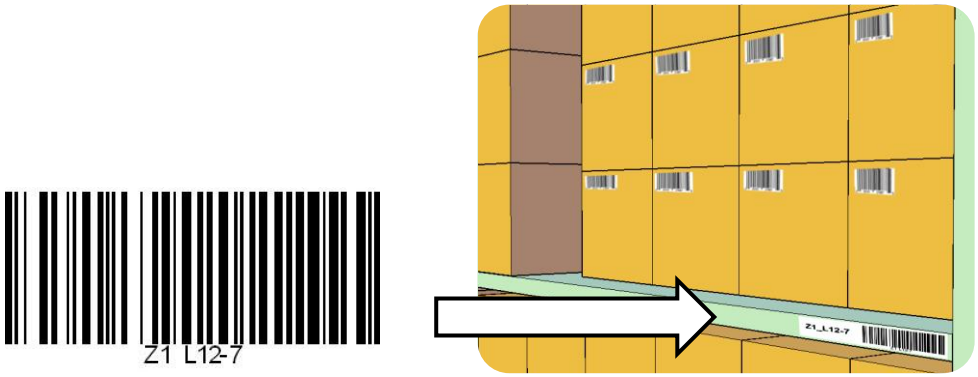
[1] *Universal Product Code*
[2] *European Article Number*
[3] *Interleaved Two of Five*
[4] *Portable Data File*

Tablica 1 - Izgledi različitih tipova barkodova. [1,15]



- **Označavanje lokacija regala**

Slika 16 pokazuje primjer označavanja lokacije regala gdje se ručnim skenerom kod skladišta s *WMS* modulom očitava lokacija s koje se komisioniraju zalihe.

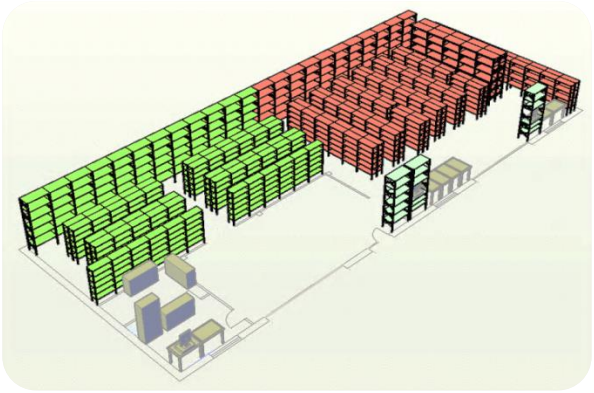


Slika 16 - Označavanje lokacije regala barkodom. [1]

3.4 ORGANIZACIJA POHRANE ROBE

3.4.1 ZONE

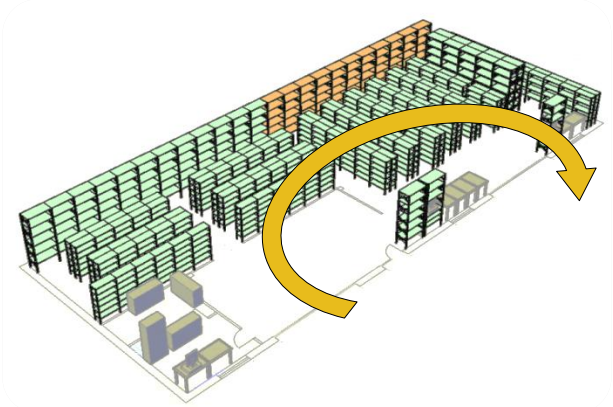
Uporaba skladišnih zona je potrebna kod većih skladišta u kojima je nemoguće označiti sve regale is dostupnim slovima abecede. Također zone se mogu koristiti i radi podijele skladišta zbog karakteristika zaliha koje to zahtijevaju. Zone mogu ali i ne moraju biti određene u zapisima lokacija, dok zone ne mogu funkcionirati bez uporabe lokacija.



Slika 17 - Skladišne zone. [1]

3.4.2 CROSS-DOCKING

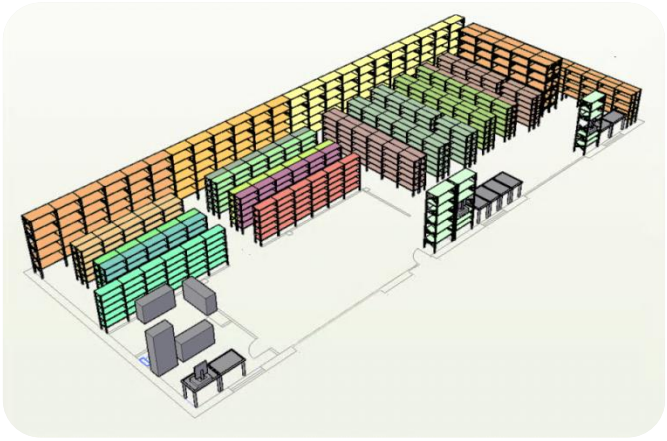
Crossdocking se upotrebljava kod robe koje se u biti ne zadržavaju, ili se zadržavaju vrlo kratko u skladištu. Ovakva vrsta robe može biti vezana za prodajne akcije koje su rijetke gdje se unaprijed znaju kupci prema čijim se narudžbama zaprimljena roba odmah obrađuje i otprema, s privremenim pozicioniranjem na regale ili određeni skladišni prostor. *Cross-docking* prostor može biti vezano za zoniranje gdje se otvara zasebna zona koja koristi isključivo toj svrsi, ili ako je potreba manja onda utječe na raspored skladišta gdje se otvara određeni dio regala za tu svrhu. Slika 18 prikazuje skladišnu suprastrukturu gdje je cross-docking manje prisutan zbog žega nema svoju zonu već određeni dio regala predodređen toj svrsi.



Slika 18 – *Cross-docking*. [1]

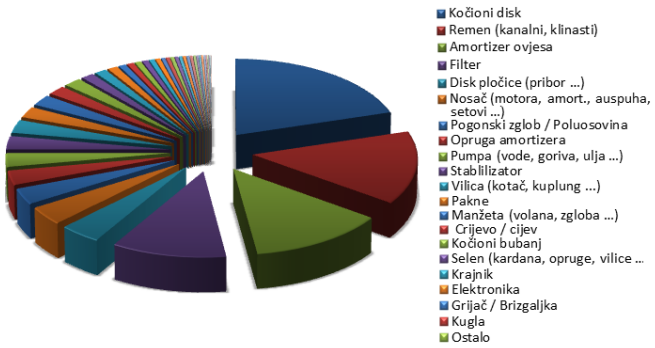
3.4.3 GRUPIRANJE

Grupiranje zaliha se odnosi na skladištenje zaliha proizvoda iz istih grupa unutar tih grupa bez međusobnog miješanja. Prednost grupiranja je što su često grupe proizvoda zbog karakteristika zaliha iste ili slične te podobnije za zajedničko uskladištenje, dok i ako se koje zalihe krivo raspreme lakše ih je locirati. Grupiranje zaliha prema grupama proizvoda također omogućuje premještaj tih grupa u slučaju manjka prostora ili neke druge manipulacije sa većim brojem zaliha. Kod skladištenja zaliha u grupe valja ostaviti među razmak između grupa s obzirom na veličinu grupa i njihovo potencijalno buduće širenje. Pri pozicioniranu grupa gledaju se karakteristike grupa na razini cijelog skladišta, pri pozicioniranju zasebnih stavki gledaju se karakteristike proizvoda na razini dodijeljenog regala grupe. Kod pozicioniranja grupe proizvoda bitno je znati „težine“ grupa kako veće grupe imaju veći obrtaj bolje ih je smjestiti bliže zoni otpreme radi smanjenja vremena rada [1,3].



Slika 19 - Prikaz skladištenja zaliha prema robnim grupama. [1]

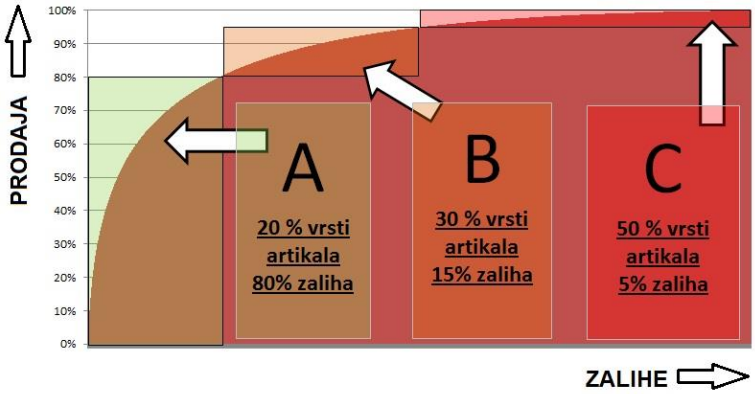
Slika 19 prikazuje robe uskladištenu po sistemu robnih grupa na regalnoj suprastrukturi. Slika 20 pokazuje međusobni odnos grupa, gdje je vidljiva različita zastupljenost određene grupe prema ostalima. Ova karakteristika je bitna kako i za način pohranu robe tako i za projektiranje suprastrukture.



Slika 20 - Prikaz međusobnih omjera robnih grupa. [1]

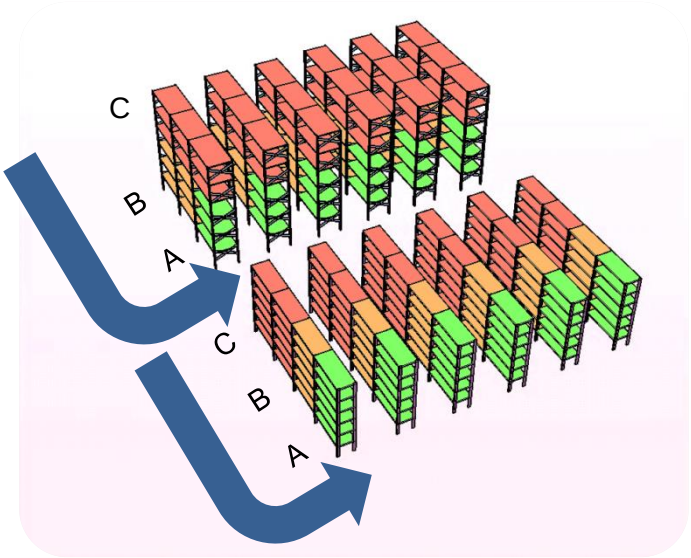
3.4.4 KATEGORIZIRANJE

ABC kategorizacija se temelji na Paretovom principu da 20% uzroka čini 80% posljedica. ABC kategorizacija u upravljanju zalihama dijeli zalihe u tri kategorije: A, B i C. Zalihe A kategorije iziskuju konstantno praćenje i upravljanje, zalihe B kategorije osrednju pozornost, a zalihe C kategorije povremenu.



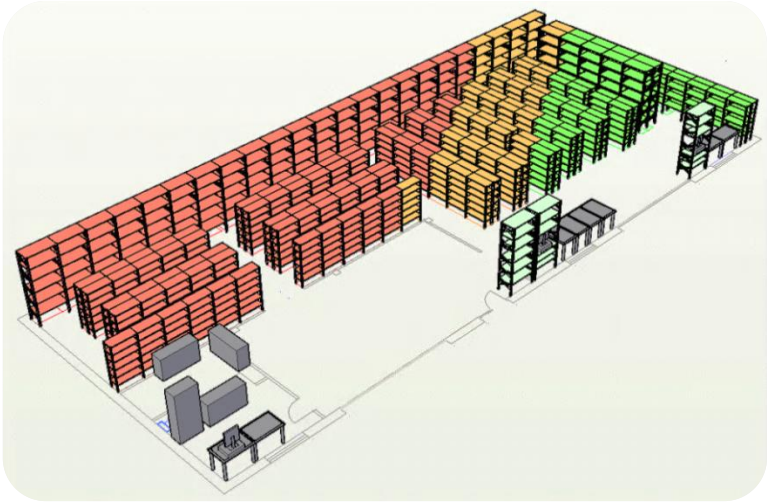
Slika 21 - Dijagram ABC kategorizacije. [1]

Kod zaliha A kategorije treba prikupljati najviše podataka jer ove zalihe čine glavninu prodaje te imaju najveći obrtaj. ABC kategorizacija se može koristiti kod upravljanja zalihama kao metoda označavanja najvažnijih zaliha bez kojih veleprodajna tvrtka ne smije ostati ni u jednom trenutku. S stajališta skladišnog upravljanja ABC analiza je korisna jer omogućuje pozicioniranje zaliha unutar skladišta po njihovoj važnosti što bi značilo da se A artikli moraju pozicionirati bliže dok C dalje u odnosu na glavne prolaze i zonu otpreme što znatno utječe na smanjenje vremena prikupljanja.



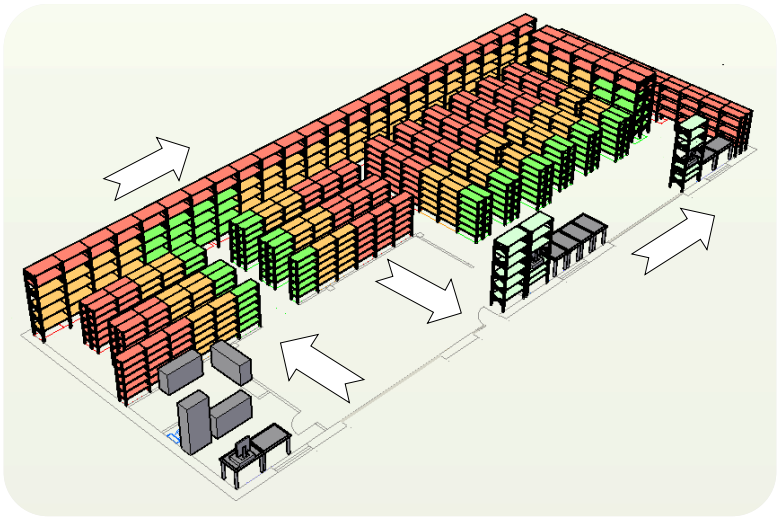
Slika 22 - ABC kategorizacija prema regalima različitih veličina. [1]

Kako je prostor skladišnog objekta ograničen, a zona otpreme najčešće na jednoj strani objekta, tako je gledano prema zoni otpreme regalni prostor blizu ili podosta daleko. Ovaj aspekt pristupa regalnog prostora naspram zone otpreme je bitan kod donošenja odluka u vezi organiziranog vođenja skladišta.



Slika 23 - ABC kategorizacija prema zoni otpreme. [1]

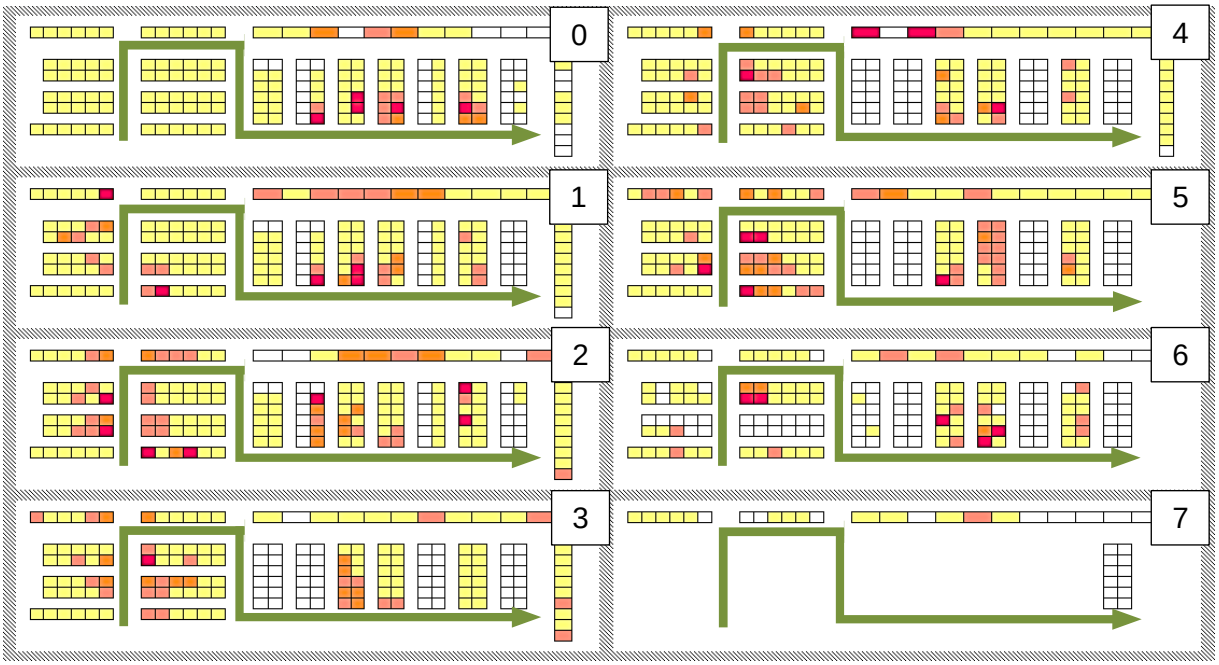
Svako skladište ima glavne prolaze prema kojima se određuje tok lokacija i raspored komisioniranja naloga. Prema tom svojstvu suprastrukture također nije ista vrijednost regalnih pozicija u sustavu pozicioniranja zaliha. Ove mikro odluke utječu na vrijeme prikupa pozitivno ili negativno, tj ovisno gdje se pozicioniraju zalihe s manjim obrtajem te one s velikim obrtajem.



Slika 24 - ABC kategorizacija prema glavnim prolazima. [1]

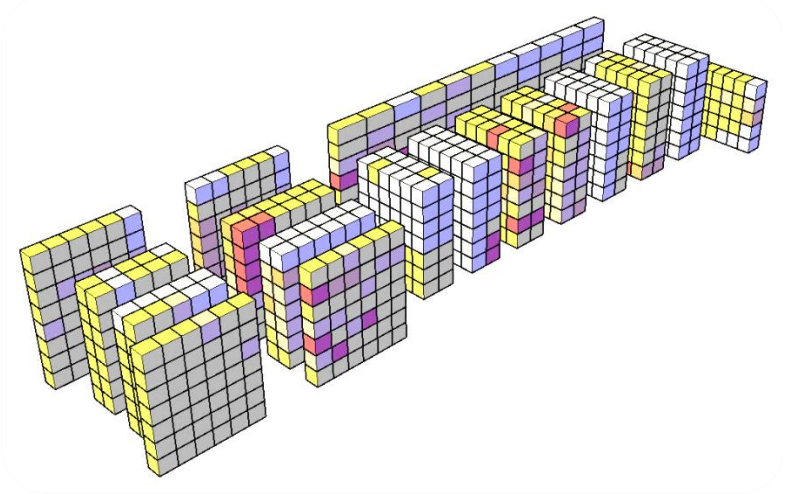
Prilikom komisioniranja i pohrane zaliha koristi se skladišna oprema unutar koje se privremeno okrupni i razvozi dio zaliha. Glavni prolazi omogućavaju manipulaciju skladišne opreme za minimalno dvije osobe istovremeno, dok među regalni prolazi mogu radi većeg iskorištenja skladišnog prostora biti manje uski, tj. dovoljno široki za rad jedne osobe.

Uporabom toplinske mape regalnog prostora može se vidjeti broj prikupa po regalu, tj. lokaciji, s obzirom na zalihe koje su pozicionirane na te lokacije. Slika 25 prikazuje primjerom kako izgleda skladištenje zaliha po ABC kategorizaciji.



Slika 25 - Prikaz toplinske mape po redovima skladišnih regala. [1,4]

Jasno je vidljiv uzorak pozicioniranja zaliha s većim obrtajem bliže glavnim prolazima kako se tijekom komisioniranja češće prikupljaju zalihe A kategorije, dok zalihe B i C kategorije zauzimaju lokacije koje su teže dostupne i kod kojih se treba napraviti veći put.



Slika 26 - 3D prikaz toplinske mape skladišnih regala. [1]

4. OPTIMIZIRANJE ZALIHA

Upravljanje zalihama se vrši radi optimizacije ponude koju tvrtka nudi s obzirom na potražnju na tržištu. Ono zahtijeva dodatne radnje osim samog naručivanja, a to su istraživanje tržišta, istraživanja mogućih dobavljača, optimizacija zaliha. Razlog upravljanja nabavom je da bi tvrtka imala zalihe kojima može prodati te s njima napraviti što veći obrtaj zaliha s time da izbjegne vezivanje kapitala za nekurentne zalihe [1,2].

Zalihe gotovih proizvoda sadrže proizvode koji su spremni za prodaju krajnjem korisniku. Zalihe gotovih proizvoda se određuju prema potražnji tržišta krajnjih korisnika. Analiza upravljanja zalihama u ovom diplomskom radu će se odnositi na gotove proizvode.

Zalihe su jedna od najvažnijih i najskupljih sredstva koje posjeduje tvrtka. Imati kurentne zalihe je ključno za dobro poslovanje. S jedne strane troškovi se mogu smanjiti s smanjenjem količina zaliha koje tvrtka ima na stanju, što može uzrokovati s nezadovoljstvom kupaca zbog manjka zaliha koje im trebaju za danju prodaju u slučaju potražnje, dok s druge strane tvrtke mogu osigurati dostupnost zaliha povećavanjem njihovih količina na stanju, u kojem slučaju postaje upitno hoće li će se sve zalihe prodati i hoće li se podmiriti troškovi kupljenih zaliha.

Uz element troška koji je vezan za zalihe, zalihe služe da reguliraju dodatne nesigurnosti poput oscilacija potražnje, izbjegavanje da nestane zaliha za koje postoji potražnja, te da omogući dobivanje jeftinijih cijena kod naručivanja većih količina zaliha [9].

Postoje dvije osnovne odluke koje se moraju donijeti kod optimizacije zalihe [5]:

1) Koliko naručiti
2) Kada naručiti

4.1 TROŠKOVI ZALIHA

Zalihe generiraju različite troškove koje se mora uzeti u obzir radi kvalitetnog upravljanja zalihama. To su [9]:

- **Trošak nabave**:

Trošak nabave sadrži troškove koji su stvoreni tijekom naručivanja zaliha. Ovaj trošak sadrži trošak tvorenja narudžbe (analiza dosadašnje prodaje i vanjskih utjecaje te predviđanje na buduću potražnju) s obzirom na varijabli vremena uloženog rada, a ne trošak izrade predviđanja i sličnih radnji. Ovi su troškovi vezani za frekvenciju naručivanje. Trošak nabave bi uključivao radnje poput sastavljanja i provjere narudžbe te pripremanje i obradu bilo kakve papirologije vezane za naručivanje. Nakon povrata informacija od proizvođača/dobavljača o potvrdi stanja narudžbe te eventualnom neispunjenju dijela narudžbe rad koja je nadalje potreban da se obradi neispunjena razlika iz narudžbe i pošalje drugom dobavljaču bi isto spadao pod trošak nabave. Dodatni troškovi vezani za nabavu mogu sadržavati i troškove telefonskih poziva, poštarina, papirologije, transporta itd.

Troškovi držanja zaliha:

- Trošak kapitala – odražava trošak kamate kredita ili određenog povrata na investiciju/posudbu kapitala;
- Trošak skladišnog objekta – sadrži troškove najma ili kupnje objekta te održavanja objekta (grijanje struja, komunalije ...);
- Trošak upravljanja zalihama – troškovi osiguranja zaliha, programske podrške i IT tehnologija, troškovi ljudskog rada s zalihama;
- Trošak rizika vrijednosti zaliha – trošak gubitka vrijednosti zaliha, posebno prisutan kod zaliha s kratkim rokom trajanja;
- Troškovi nekurentnih zaliha - ovi troškovi nastaju kada potražnja za određenim zalihama prestane postojati, u kojem slučaju nastaju nekurentne zalihe koje vežu kapital kojeg je u tom slučaju teško povratiti.

Troškovi nezadovoljenja potražnje:

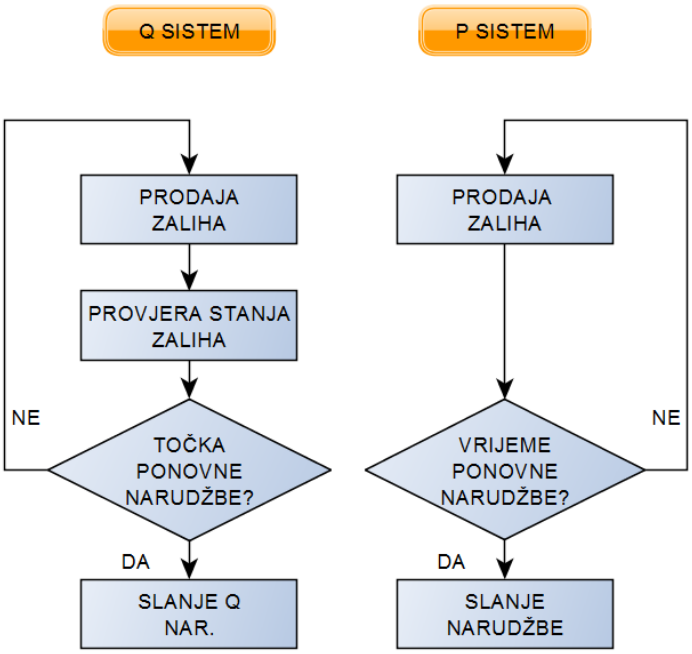
Ovi troškovi nastaju kada se narudžba kupca ne ispuni. Ovi troškovi se dijele u dvije kategorije:

- Troškovi izgubljenog profita – ovi troškovi odražavaju izgubljeni profit koji nastaje prilikom neispunjenja potražnje. Kupac može također povući cijelu narudžbu u slučaju da dio narudžbe nije ispunjen;
- Troškovi *backordera*[5] – *backorderi* su narudžbe koje se ispunjavaju nakon što se prvobitna narudžba ne ispuni, u ovom slučaju je kupac voljan pričekati da mu se narudžba ispuni.

[5] *Backorder* – narudžba koja nije prvobitno ispunjena radi nedostupnosti tražene robe, a koja će se ispuniti sljedećom obnovom stanja zaliha.

4.2 MODELI KONTROLE RAZINE ZALIHA

Postoje dva opća pristupa kontroliranja razine zaliha na razini jednog subjekta unutar opskrbnog lanca: Q i P sistem [9]. Q model se bazira na konstantnoj provjeri razine zaliha. Kada količina zaliha dosegne predefiniranu količinu (točka narudžbe), fiksna količina robe se šalje na naručivanje. Kod P modela stanje zaliha se provjerava samo u predodređenim vremenima, kod kojih se onda se šalje varijabilna količina narudžbe zaliha.



Dijagram 11 - Dijagram toka P i Q modela. [1]

Dijagram 11 pokazuje različitost pristupa kontrole razine zaliha između P i Q modela. Glavna razlika se sastoji u tome da se kod Q modela računa točka ponovne narudžbe za robu dok se kod P modela koristi periodično vrijeme narudžbe određeno od strane logističkog operatera.

Tablica 2 - Usporedba karakteristika P i Q modela. [1]

	Q model	P model
Q	Konstantan	Varijabilan
Vrijeme slanja narudžbe	R - Točka narudžbe	T - vrijeme između narudžbi
Kontrola zaliha	Konstantna	Povremena
Količina lagera	Manja od P modela	Veća od Q modela
Vrijeme uloženo u narudžbe	Dugotrajno	Kratkotrajno

Tablica 2 prikazuje usporedbu spomenutih glavnih karakteristika P i Q modela.

Tablica 3 pokazuje kako se mijenja način kontroliranja razine zaliha s obzirom na spomenute modele kontrole razine zaliha. Kako veleprodajne tvrtke načuju robu u velikoj količini jedini prikladan model je P model. Q model izračunava optimalnu točku narudžbe po vrsti robe što uzrokuje različitim vremenima narudžbe što nije prikladno za naručivanje gdje se roba okrupljuje što iziskuje veleprodajna tvrtka kod naručivanja robe.

Tablica 3 - Usporedba vremena provjere razine zaliha kod Q i P modela. [1]

	Fiksan Q	Varijabilan Q
Kontinuirana provjera zaliha	x	
Periodična provjera zaliha		x

Varijable [2]:

- Potražnja D - Potražnja koja je količinski ista za svaki period pregleda stanja zaliha se smatra konstantnom potražnjom. Potražnja koja se mijenja tijekom perioda pregleda stanja zaliha se smatra varijabilnom potražnjom;

- Vrijeme isporuke L - Vrijeme koje prođe od trenutka slanja narudžbe do dostupnosti zaliha za komisioniranje u skladištu;

- Broj dana između narudžbe T - Vrijeme koje prođe između dvije narudžbe. Kod P modela zalihe se provjeravaju u određenim intervalima, prema kojima se rade i narudžbe. Ako se jednom tjednom provjerava stanje zaliha onda je T = 7 dana.

Za veleprodajnu tvrtku način dopreme / isporuke robe tvrtci određuje koji će se model koristiti. Kako se isporuka za veleprodajnu tvrtku doprema u okupljenom obliku u većim količinama, tako je moguće vršiti naručivanje robe u određenim intervalima gdje naručene količine moraju zadovoljiti predviđenu potražnju za vremenski period do sljedećeg punjenja zaliha.

- **P MODEL**

P model se bazira na fiksnom vremenu naručivanja, prema kojemu se određuje količina zaliha prilikom naručivanja. Pretpostavke [9]:

1. Konstantna nasumična potražnja (normalna distribucija): D;
2. Vrijeme isporuke: L >0;
3. Vrijeme između narudžbi: T>0.

U modelu koji ima fiksno vrijeme između narudžbi, zalihe se prebrojavaju samo u tim predviđenim trenucima, poput svaka dva tjedna ili jednom mjesečno. Ovakav model određuje količinu narudžbe zaliha koja se mijenja od ciklusa do ciklusa ovisno o mijenjanju potražnje. Takvo održavanje zaliha zahtijeva veći nivo sigurnosnih zaliha zbog povremene provjere stanja zaliha za razliku od Q modela koji kontinuirano prati stanje zaliha što omogućava trenutačnu narudžbu zaliha kada nivo zaliha padne na točku ponovne narudžbe. Moguće je kod modela s fiksnim vremenom naručivanja da nepredvidiva potražnja povuče sve zalihe određenog proizvoda s stanja što će vjerojatno ostati ne zamijećeno do sljedećeg vremena narudžbe. Formule za izračun optimalne količine zaliha [9]:

- Sigurnosne zalihe:

$$ss = z\sigma_D\sqrt{T+L}$$

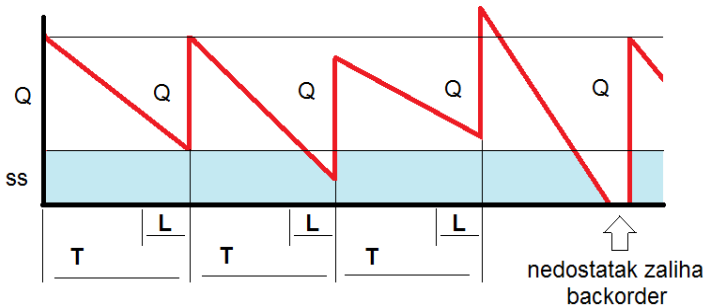
- Količina narudžbe:

$$Q = \bar{d}(T+L) + z\sigma_D\sqrt{T+L} - I$$

- Devijacija potražnje:

$$\sigma_D = \sqrt{\frac{\sum(d-\bar{d})^2}{n}}$$

- Q – količina narudžbe;
- T – broj dana između narudžbe;
- L – vrijeme isporuke (vrijeme između slanja narudžbe i vremena raspoloživosti zaliha u skladištu);
- $\bar{d}$ – prosječna dnevna potražnja;
- z – stopa usluge;
- I – trenutno stanje zaliha.
- σ_D – devijacija potražnje



Dijagram 12 - P model. [1,3]

4.3 KOEFICIJENT OBRTAJA ZALIHA

Prodaja zaliha je glavni cilj trgovačke tvrtke, zalihe se kupuju da bi se ponovno prodale. Taj obrtaj prodanih zalihe je jako bitan, pogotovo kod tvrtci koje imaju malu maržu. Što je brži obrtaj, to jest veći, to je ostvarena veća zarada.

Mjera kvalitetne kontrole razine i vrste zaliha je koeficijent obrtaja zaliha (*inventory turnover ratio*). Koeficijent obrtaj zaliha pokazuje koliko su se puta prodale zalihe unutar nekog područja, uglavnom unutar jedne godine [9].

$$\textbf{Koeficijent obrtaj zaliha} = \frac{trošak\ prodanih\ zaliha}{prosječne\ zalihe}$$

$$Prosječne\ zalihe = \frac{\text{vrijednost početnih zaliha } + \text{ vrijednost krajnjih zaliha}}{2}$$

$$Trošak\ prodanih\ zaliha = početne\ zalihe + kupljene\ zalihe - krajnje\ zalihe$$

$$\boldsymbol{Dani\ vezivanja\ zaliha} = \frac{365\ dana}{koeficijent\ obrtaja\ zaliha}$$

Niski koeficijent obrtaja zaliha je znak manjka efektivnosti, odražava slabu likvidnost, slabu prodaju, tj. tendenciju krajnjeg smanjenja obrtaja zaliha na nulu. Također razlog malog koeficijenta zaliha mogu biti i prevelike zalihe gdje razina zaliha daleko nadmašuje potražnju na tržištu. Ovaj pokazatelj na godišnjoj razini pokazuje dali se isplati razina visokih zaliha u slučaju da se nabava odrađuje van optimalnih količina zaliha prema potražnji.

Visoki koeficijent obrtaja zaliha naznačava da je prodaja zdrava i da je likvidnost tvrtke dobra.

5. PROGNOZA POTRAŽNJE

Nakon analiziranja optimalnih zaliha bitno je predvidjeti potražnju koja u tom slučaju služi kao potpora odlučivanju kod naručivanja zaliha u budućem periodu za koji se vrši nabava. Prognozom potražnje se predviđa količina proizvoda ili usluge koju će kupac kupiti. Predviđanje se vrši s tehnikama koje mogu biti kvantitativne ili kvalitativne prirode. Predviđanje potražnje se može koristiti radi određivanja količine zaliha, donošenja odluka vezanih za cijene proizvoda, donošenje odluka vezanih za ulazak na tržište i slično. Da bi se prognoza izvela kvalitetno treba uvidjeti elemente dobre prognoze i korake prognoze:

- **Elementi dobre prognoze** [2]:

1) Cikličnost – prognoze zavise o vremenu, tako je uobičajeno potrebno određeno vrijeme da bi se informacije proizvedene prognozom odrazile na stvarnost. Vremenski interval treba uzeti u obzir potrebno vrijeme da bi se planirane promjene mogle implementirati u stvarnost;
2) Točnost – prognoza treba biti točna, gdje točnost treba biti izražena kvantitativnim vrijednostima. To će omogućiti operateru da prilikom planiranja uzme u obzir potencijalne greške;
3) Pouzdanost – prognoza mora biti dosljedna. Tehnike koje nekada daju dobre, a nekada loše rezultate stavljaju operatera u nezgodnu situaciju jer je upitna ispravnost prognoziranih podataka;
4) Značajne jedinice – prognoza treba biti izražena u značajnim vrijednosnim jedinicama. Bitno je znati koje su vrijednosti vezane za jedinice naručivanja, te unutar kojeg vremena;
5) Jednostavnost i razumljivost – operateri često gube pouzdanje u metode prognoze jer su bazirane na kompliciranim tehnikama, zbog tog razloga relativno jednostavne tehnike prognoze su šire prihvaćene i češće se upotrebljavaju;
6) Isplativost – prognoze trebaju biti isplative, prednosti trebaju nadmašiti troškove.

- **Koraci prognoze** [2]:

1) Određivanje svrhe prognoze – kako i kada će se koristiti? Ovaj korak će omogućiti određivanje potrebnih detalja vezanih za izradu analize (novac, tehnika, ljudi ...);
2) Određivanje vremenskih intervala – svaka prognoza se izvodi unutar određenih vremenskih intervala, s time da se točnost prognoze smanjuje što se vremenski interval povećava;
3) Uporaba čistih i prikladnih podataka – točnost prognoza ovisi o podacima na kojima se ona temelji;
4) Odabir tehnike prognoze – prema obliku poslovanja, te za njega vezanim mogućnostima i nedostacima, treba odabrati prikladnu tehniku prognoze potražnje.
5) Izrada prognoze – izrada modela koji će se koristiti;
6) Praćenje prognoze – rezultati prognoze se moraju pratiti i evaluirati da bi se moglo ocijeniti dali prognoza daje zadovoljavajuće rezultate. Ako rezultati ne zadovoljavaju mora se ponovno procijeniti prikladnost odabrane metode, zadane pretpostavke, kredibilitet podataka ... Valja zamijetiti da u slučaju smanjenje predviđene potražnje treba uzeti u obzir dali je došlo do mijenjanja cijena.

- **Vrste prognoza**

Postoje dva glavna pristupa kod prognoziranja potražnje, kvalitativan i kvantitativan [1,2,10]. Kvalitativne metode se sastoje od subjektivnih ulaza, koji često nisu u skladu s točnim brojčanim podacima. Kvantitativne metode uključuju projekciju povijesnih podataka. Kvalitativne tehnike dozvoljavaju unos informacija poput ljudskih faktora, razmišljanja osoblja, slutnji i sličnoga u proces prognoze. Ti faktori se često eliminiraju kod kvantitativnih metoda jer ih je teško, pa i nemoguće, kvantificirati.

- Kvalitativne prognoze

U nekim situacijama, prognoze se oslanjaju isključivo na prosuđivanje i iskustvo. Ako operaterima treba prognoza u kratkom roku, vjerojatno neće biti dovoljno vremena da se skupe i analiziraju kvantitativni podaci. U drugim slučajevima može doći do političkih i ekonomskih promjena koje će učiniti postojeće podatke zastarjelim. Slično tome, plasiranje novih proizvoda na tržište ne može biti logistički poduprto kvantitativnim prognozama zbog oskudice povijesnih podataka na kojima bi se bazirale. U takvim slučajevima, prognoze se baziraju na prosuđivanjima ključnih osoba, anketiranja tržišta, razmišljanja stručnjaka i slično. Ovakvo dugoročno planiranje koje izrađuje nekoliko ključnih osoba ima za prednost korištenje značajnog iskustva različitih stručnjaka, dok u je nedostatak rizik da će razmišljanje jedne osobe prevaliti što može ugroziti kvalitetu prognoze.

Neke od kvantitativnih prognoza [10]:

- *Ekspertne* skupine **-** pristup se koristi za međusobnu komunikaciju i podjelu informacija temeljem kojih se radi prognoza;
- Delphi metoda **-** strukturirana tehnika kojom se nastoji dobiti zajednički zaključak, pri čemu se eksperti ne moraju okupiti na istoj lokaciji. Tehnika je osmišljena na način da se izbjegne utjecaj eksperata s većim/jačim autoritetom na stvaranje konačnog zaključka;
- Prognoze analizom tržišta **-** kvalitativne studije ponašanja i djelovanja potrošača- posebno je značajna u postupku uvođenja novih proizvoda na tržište. Ciljanoj grupa potrošača daje se na testiranja određen proizvod ili grupa proizvoda; rezultati se analiziraju i temeljem njih se izrađuje prognoza potražnje;
- Osobna prosudba;
- Teorija igara;
- *Jury of executive* metoda.

- Kvantitativne metode

Kvantitativne metode se baziraju oko regularnih vremenskih intervala. Podaci mogu mjeriti potražnju, zaradu, profit, produktivnost itd. Kvantitativne vremenske metode se baziraju na pretpostavci da će se buduće vrijednosti moći procijeniti iz povijesnih vrijednosti. Premda se ne identificiraju razlozi varijabli, ove metode se opće prihvaćene i imaju veliku uporabu u poslovnom svijetu zbog zadovoljavajućih rezultata koje daju. Analiza podataka zahtijeva identificiranje ponašanja serije podataka unutar ciklusa. To se može postići tako da se jednostavno u grafu prikažu podaci. Jedan ili više uzoraka se može pojaviti na dijagramu: trend, sezonske varijacije, cikličnost ili varijacije oko prosjeka. Dodatno k tome, pojavljivati će se nasumične i ne regularne varijacije.

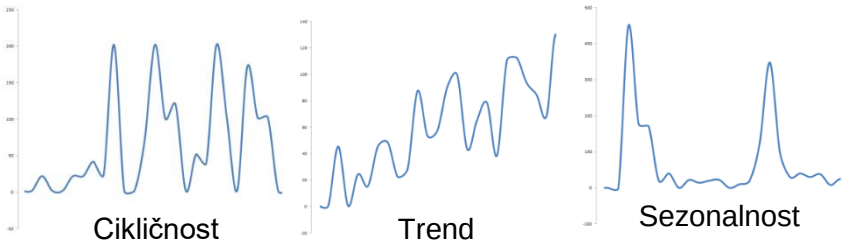
Neke od kvantitativnih prognoza [2, 10]:

- Vremenske metode – pokušavanje projiciranja prošlog iskustva u budućnost. Temelje se na pretpostavci da je analiza obrasca narudžbi tijekom određenog vremenskog perioda pokazatelj potražnje u budućnosti;
- Uzročne metode - prognoze se temelje se povezivanju uzroka i posljedica. Primjerice potražnje za novcem povezana je s visinom kamata;
- Diskretne simulacije (*DES*);
- Ekstrapolacija;
- Rudarenje podataka.

Važno je napomenuti da se prognoza potražnje treba bazirati na povijesnim podacima potražnje, a ne na prodaji jedinica. Prognoza koja se bazira na prodaji jedinica neće moći kvalitetno predvidjeti potražnju ako dođe do potpune prodaje zalihe. Potražnja zaliha koje nisu na raspolaganju za prodaju mora biti evidentirana jer ona odražava stvarnu potražnju, dok prodaja jedinica odražava isključivo realiziranu prodaju.

- **Vrste potražnje**

Potražnja se kvantitativno promatra kroz redovne intervale (sat, dan, tjedan, mjesec, godina) te može izražavati informacije poput zarade, prodaje, profit, produktivnost itd. Modeli prognoze potražnje se baziraju na pretpostavci da se na temelju povijesnih podataka može predvidjeti buduća potražnja. Slika 27 ilustrira različitost potražnje.



Slika 27 - Oblici potražnje. [1,2]

Analiza podataka potražnje zahtijeva da se prepozna ponašanje potražnje. To se najčešće može izvršiti tako da se podaci prikažu na dijagramu. Analizom potražnje se mogu uočiti sljedeći elementi prisutni u podacima [2]:

1) Trend – obilježava dugoročni ili pad rast vrijednosti unutar podataka;
2) Sezonalnost – kratkotrajna, regularna varijacija unutar podataka koja se najčešće veže za određene datume unutar godine;
3) Cikličnost – valovite varijacije unutar podataka koje su regularne i češće;
4) Ne regularna odstupanja – izražena odstupanja unutar podataka koje ne odražavaju tipično ponašanje podataka. Ova odstupanja mogu ugroziti ispravnost prognoze;
5) Regularna odstupanja – opće prisutne varijacije unutar podataka

5.1 TOČNOST PROGNOZE

Točnost prognoze je važan faktor kod odlučivanja između raznih metoda prognoza. Točnost se bazira na povijesnim greškama prognoze. Točnost izrađenih prognoza potražnje se mjeri pomoću grešaka između predviđenih količina i stvarne potražnje. Postoje tri najčešće upotrebljavane metode izračuna greške prognoze [2]:

- Srednje apsolutno odstupanje (*mean absolute error* - MAE);

$$MAE = \frac{\sum |D - F|}{n}$$

- Korijen srednje kvadratne pogreške (*root mean squared error* - RMSE);

$$RMSE = \sqrt{\frac{\sum (D - F)^2}{n}}$$

- Prosječna postotna apsolutna pogreška (*mean absolute percent error* - MAPE).

$$MAPE = \frac{\frac{\sum |D - F|}{D} * 100}{n}$$

Gdje je:

- D – potražnja;
- F – predviđanje;
- e – greška.

Razlika između ovih metoda je ta da MAE jednako vrednuje sve greške, RMSE vrednuje greške prema njihovim kvadriranim vrijednostima, tj. pojačava i izvlači veće greške, dok MAPE vrednuje vrijednosti prema relativnim greškama. MAE metoda je najlakša za izračunati, ali vrednuje greške linearno. RMSE kvadrira greške, time dajući više težine kod većih grešaka, što uzrokuje više problema. MAPE bi se trebao koristiti tada kada treba greške staviti u perspektivu. Na primjer. Greška od 10 u prognozi od 15 je velika greška. Suprotno tome, greška od 10 u prognozi od 10 000 je nevažna.

Uporabom metoda točnosti prognoze možemo usporediti točnost postojećih kvantitativnih metoda prognoze potražnje.

5.2 KVANTITATIVNE METODE PROGNOZE POTRAŽNJE

U danjem tekstu će biti obrađene kvantitativne metode koje se najčešće upotrebljavaju u području predviđanja potražnje [2].

1) Naivna metoda;
2) Prosjeci;
3) Eksponencijalno izglađivanje;
4) Dvostruko eksponencijalno izglađivanje (Holt metoda);
5) Trostruko eksponencijalno izglađivanje (Holt Winters metoda).

- **Naivna metoda**

Jednostavna ali široko upotrebljavana metoda prognoze potražnje je naivna metoda. Naivna metoda prognoze potražnje upotrebljava jednu zadnju vrijednost unutar baze podataka koja se koristi za prognozu. Naivna metoda se može koristiti sa stabilnom serijom podataka koja varira oko prosjeka, kod sezonskih varijacija, ili kod trenda. Kod stabilne serije, zadnja vrijednost podataka postaje točka za predviđanje potražnje za sljedeći period. Prema tome ako je 10 komada proizvoda prodano unutar mjesec dana, prognoza potražnje proizvoda za sljedeći tjedan će iznositi 10 komada.

Kod sezonskih varijacija predviđanje potražnje će biti kao i kod prošlogodišnje sezonske varijacije. Kod podataka s trendom vrijednost predviđanje potražnje je jednaka zadnjoj vrijednosti plus ili minus razlika između zadnje dvije vrijednosti podataka.

Tablica 4 - Izračun naivne metode. [2]

Mjesec	Potražnja	razlika	potražnja
1	10		
2	12	2	
3			**14**

- **Prosjeci**

Povijesni podaci sadrže određenu količinu nasumične varijacije koja čini nerazumljivim sistematsko kretanje podataka. Ta nasumičnost proizlazi iz kombiniranih utjecaja koji se ne mogu pouzdano predvidjeti. Prosjeci izglađuju varijacije unutar podataka. Idealno bi bilo poželjno da se potpuno odstrane varijacije iz podataka te da se ostave samo prave varijacije koje odražavaju potražnju. U stvarnosti je često nemoguće razlikovati te dvije varijacije, tako da se operater može nadati da su male varijacije potražnje slučajne, a velike stvarne.

Tehnike izračuna prosjeka stvaraju prognozu koja odražava nedavne vrijednosti zadnjih nekoliko perioda. Ove tehnike nabolje funkcioniraju unutar serija koje teže variranju oko prosjeka. Premda prosjeci mogu podnijeti nagle i postepene promjene unutar podataka često je prisutno zaostanje predviđanja prema stvarnim podacima.

Postoje tri tehnike za izračun prosjeka [2]:

a) Pomični prosjek;
b) Težinski prosjek;
c) Eksponencijalno izglađivanje.

- **Pomični prosjek**

Jedan nedostatak naivne metode je taj da previđanje samo precrtava stvarne podatke, sa zaostatkom od jednog perioda, bez izglađivanja podataka. Sa proširivanjem količine povijesnih podataka na kojima se bazira prognoza taj problem se može riješiti. Predviđanje pomičnim prosjecima koriste se više zadnjih vrijednosti za stvaranje predviđanja. Formula navedene metode [2]:

$$F_n = \frac{\sum_{i=1}^{n} D_{t-1}}{n} = \frac{D_{t-n} + \cdots + D_{t-2} + D_{t-1}}{n}$$

- F_n – pomični prosjek za n perioda;
- t – vremenski period;
- n – broj perioda;
- D_{t-1} – potražnja perioda $_{t-1.}$

- **Težinski prosjek**

Ova tehnika je poput pomičnog prosjeka, s time da određenim podacima dodaje različita težinska vrijednost. Na primjer najnovijom vrijednostima se može dodati težina od 0.50, vrijednost prije te težina od 0.30, dok npr. u seriji krajnjoj vrijednosti težina od 0.20. Odabir težina koje će se koristiti za vrijednosti je arbitraran te najčešće zahtjeva isprobavanje da bi se našle optimalne vrijednosti. Formula navedene metode [2]:

$$F_t = w_t(D_t) + w_{t-1}(D_{t-1}) + \cdots + w_{t-n}(D_{t-n})$$

- w_t – težina za period t;
- D_t – vrijednost potražnje perioda.

- **Eksponencijalno izglađivanje**

Eksponencijalno izglađivanje je sofisticirana tehnika koju je relativno lako koristiti. Svaka nova prognoza se bazira na prošloj prognozi plus postotak razlike između te prognoze i stvarnih vrijednosti serije za koju se izračunava.

Eksponencijalno izglađivanje dodjeljuje eksponencijalno manje vrijednosti kako su povijesni podaci sve stariji. Novijim podacima se daje više težine nego starijima. Kod prosjeka težina je ista kod svih podataka (1/n). Formule navedene metode [2]:

$$F_t = F_{t-1} + \alpha(D_{t-1} - F_{t-1})$$

- F– predviđanje;
- α – konstanta izglađivanja (postotak);
- D – potražnja .

Konstanta izglađivanja predstavlja postotak greške predviđanja. Svako novo predviđanje je jednako prošlom plus postotak prijašnje greške. Na primjer, pretpostavkom da je prošla potražnja bila 15 jedinica, a stvarna potražnja 13 jedinica, dok α = 0,1.

$$F_t = 15 + 0{,}10(13 - 15) = 14{,}8$$

Nakon čega ako bi stvarna potražnja bila 16 jedinica, sljedeća prognoza bi dala:

$$F_t = 14{,}8 + 0{,}10(16 - 14{,}8) = 14{,}92$$

Brzina reakcije prognoze na pogrešku ovisi o konstanti izglađivanja. Što joj je bliže vrijednost nuli, prognoza će se sporije prilagoditi greškama unutar prognoze. Što je veća vrijednost konstante jedinici brža će biti reakcija no manje izglađivanje. Odabir vrijednosti konstante se vrši kroz pokušaje i greške, s time da se koriste greške predviđanja koje vode tu odluku. Cilj je odabrati konstantu koja balansira koristi izglađivanja sa koristi bržih prilagodbi promjenama. Najčešće upotrebljavane vrijednosti su unutar područja od 0,05 do 0,5.

Važno je kod ove tehnike da izračun mora početi nekoliko perioda prije da bi se omogućilo potražnji da se prilagodi podacima. Različiti pristupi se mogu koristiti da se dobije početna potražnja, poput izračuna prosjeka za prvih nekoliko perioda, može se također koristiti i subjektivna procjena itd.

- **Dvostruko eksponencijalno izglađivanje**

Dvostruko eksponencijalno izglađivanje se definira kao eksponencijalno izglađivanje eksponencijalnog izglađivanja. Ova metoda se također naziva i Holtova metoda. Eksponencijalno izglađivanje ne pogoduje podacima gdje se pojavljuje trend. Ta situacija se može poboljšati uporabom β varijable, tj. trend komponente, koja se odabire s obzirom na α varijablu. Prognoza potražnje se sastoji od zbroja dvije komponente, nivoa i trenda. α varijabla služi kao parametar za izglađivanje nivoa (*level) zaliha, dok* β varijabla služi kao parametar za izglađivanje trenda potražnje. Jednadžba nivoa potražnje pokazuje da je l_t težinski prosjek promatrane potražnje D_t, dok je jednadžba trenda težinski prosjek vremena t baziranog na razlici nivoa $l_t - l_{t-1}$ i zbroja s trendom b_{t-1}. Formule navedenog modela [2]:

- Predviđanje:

$$F_1 = 0: \qquad F_t = l_t + b_t$$

- *Level* formula:

$$l_1 = D_1; \qquad l_t = \alpha D_t + (1-\alpha)(l_{t-1} + b_{t-1})$$

- Trend formula:

$$b_1 = 0; \qquad b_t = \beta(l_t - l_{t-1}) + (1-\beta)b_{t-1}$$

- **Trostruko eksponencijalno izglađivanje**

Trostruko eksponencijalno izglađivanje je metoda prikladna za podatke kod kojih je prisutan trend i sezonalnost. Ova metoda se također zove i Holt Winters metoda. Specifična je po varijabli ɣ koja predstavlja sezonalitet. Dodavanjem treće varijable podaci se de sezonaliziraju. Formule navedenog modela [2]:

Ako je:

- ɣ = 1, onda je sezonalnost tipična;
- ɣ < 1, onda je sezonalnost manja od tipične;
- ɣ > 1, onda je sezonalnost veća od tipične.

Holt Winters metoda je slična eksponencijalnom izglađivanju ako je β i ɣ = 0, dok je slična dvostrukom izglađivanju ako je ɣ = 0.

Pomični prosjek se često koristi da se izglade kratkoročne promjene u potražnji te da se utvrde dugoročni trendovi i ciklusi. Prostor između kratkoročnih i dugoročnih promjena ovisi o podacima, prema kojima će se i pripadajuće tri varijable i podesiti.

Eksponencijalno izglađivanje se je pokazala kao korisna metoda, koja je korisna kod podataka koji nemaju trend i sezonalnost. Holt je nadogradio tu metodu s komponentom trenda, dok Winters s komponentom sezonalnosti.

- **Sezonalnost**

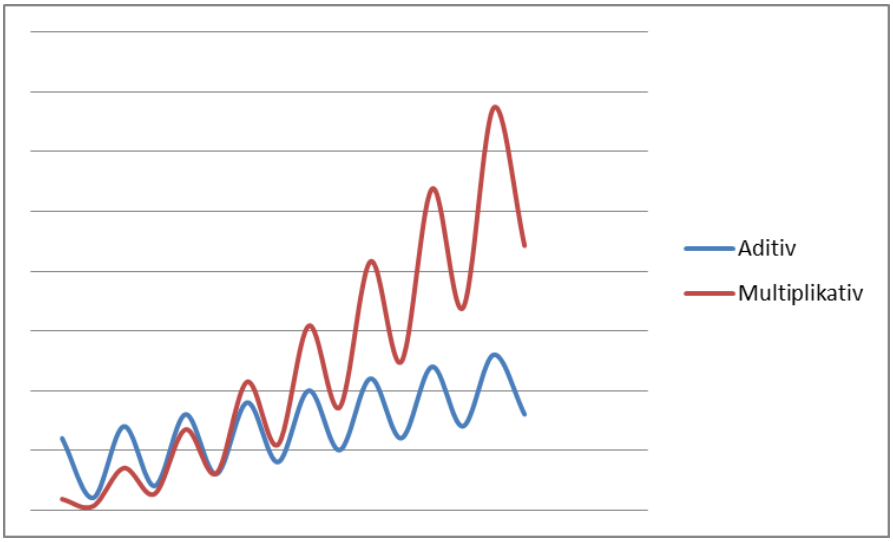
Sezonalnost se odnosi na regularno ponavljajuće kretanje prema gore i dolje unutar serije podataka koje se može povezati sa nekakvim događajima. Termin sezonalnost se također može upotrijebiti u tjednim i mjesečnim periodima gdje se pojavljuju redovne varijacije unutar podataka.

Sezonalnost se u prognozama izražava u vrijednostima odstupanja stvarne potražnje od prosjeka serije. Postoje dva različita modela za sezonalnost; aditivni i multiplikativni [2].

a) Multiplikativni model – sezonalnost izražava kao postotak prosjeka količine, koji se onda koristi da se množi vrijednost serije da bi se ukomponirala sezonalnost u prognozu.
b) Aditivni model – sezonalnost izražava količinom, koja se dodaje ili oduzima od prosjeka serije da bi se ukomponirala sezonalnost u prognozu;

U praksi se multiplikativni model koristi u širokoj primjeni zato jer daje rezultate bliže stvarnosti. sezonski postoci u multiplikativnom modelu se nazivaju sezonski indeksi. Sezonski indeks vrijednost 1,5 govori da je za taj period potražnja 50% veća od prosjeka, dok sezonski indeks vrijednosti od 0,5 govori da je potražnja 50% manja od prosjeka. Poznavanje sezonskih varijacija je važan faktor u planiranju i predviđanju. Također sezonalnost može biti važan faktor u planiranju količina zaliha za određeni period.

Dijagram 13 prikazuje razliku između multiplikativa i aditiva. Multiplikativ ima tendenciju eksponencijalnog rasta dok aditivni linearnog rasta.



Dijagram 13 - Prikaz multiplikativa i aditiva. [1,2]

Da bi ocijenili efikasnost navedenih metoda u praksi sljedeći korak je njihova međusobna analiza.

a) Multiplikativni model

Varijabla α služi kao parametar za izglađivanje nivoa (level) zaliha "l", dok β varijabla služi kao parametar za izglađivanje trenda potražnje „b". Varijabla γ služi kao parametar za izglađivanje sezonske komponente „s". Multiplikativni model sezonalnost izražava kao postotak prosjeka količine, koji se onda koristi da se množi vrijednost serije da bi se ukomponirala sezonalnost u prognozu; $\gamma(D_t/l_t)$. Formule navedenog modela [2]:

- Period:

$$p = t_n$$

- *Level* formula (p=4):

$$l_1 = D_1 \; ; \qquad l_{2,3,4} = \alpha D_t + (1-\alpha)(l_{t-1} + b_{t-1})$$

$$l_t = \alpha(D_t/s_{t-4}) + (1-\alpha)(l_{t-1} + b_{t-1})$$

- Trend formula:

$$b_1 = 0 \; ; \qquad b_t = \beta(l_t - l_{t-1}) + (1-\beta)b_{t-1}$$

- Sezonalnost formul (p=4):

$$s_{1,2,3,4} = 1 \; ; \quad s_t = \gamma(D_t/l_t) + (1-\gamma)s_{t-p}$$

- Predviđanje (p=4):

$$F_{1,2,3,4} = 0 \; ; \quad F_t = (l_{t-1} + b_{t-1}) * s_{t-p}$$

a) Aditivni model

Varijabla α služi kao parametar za izglađivanje nivoa (*level) zaliha"l", dok* β varijabla služi kao parametar za izglađivanje trenda potražnje „b". Varijabla γ služi kao parametar za izglađivanje sezonske komponente „s". Aditivni model sezonalnost izražava kao razliku potražnje i level vrijednosti, koji se onda koristi da se množi vrijednost serije da bi se ukomponirala sezonalnost u prognozu; $\gamma(D_t - l_t)$. Formule navedenog modela [2]:

- Period:

$$p = n_t$$

- *Level* formula (p=4):

$$l_1 = D_1 \; ; \qquad l_{2,3} = \alpha D_t + (1-\alpha)(l_{t-1} + b_{t-1}) \; ; \quad l_4 = {}^{D_1 + \cdots + D_4}/_{p}$$

$$l_t = \alpha(D_t - s_{t-p}) + (1-\alpha)(l_{t-1} + b_{t-1})$$

- Trend formula:

$$b_1 = 0 \; ; \qquad b_t = \beta(l_t - l_{t-1}) + (1-\beta)b_{t-1}$$

- Sezonalnost formula (p=4):

$$s_{1,2,3,4} = D_t - l_{p=4} \; ; \quad s_t = \gamma((D_t - l_t) + (1-\gamma)s_{t-p}$$

- Predviđanje (p=4):

$$F_{1,2,3,4} = 0 \; ; \quad F_t = l_{t-1} + b_{t-1} + s_{t-p}$$

5.3 ODABIR METODE PROGNOZE

Postoje mnoge tehnike prognoze, ni jedna od njih ne funkcionira optimalno kod svake vrste potražnje. Pri odabiru tehnike, logistički operater mora uzeti više faktora u odabir.

Dva najvažnija faktora su cijena i točnost. Koliko je novca određeno za prognozu, koji su mogući troškovi generirani greškama, koje su koristi točne prognoze itd. Drugi faktori koji se uzimaju u obzir su prisutnost povijesnih podataka, dostupnost računalnih programa, mogućnost skupljanja podataka itd. Doseg prognoze je isto bitan jer su neke tehnike prikladnije za dugoročno predviđanje dok neke za kratkoročno predviđanje [2].

Pomični prosjeci i eksponencijalno izglađivanje su u tehnike kratkoročne prognoze jer izračunavaju vrijednosti samo za sljedeći period. Tehnika trenda može projicirati dugoročno potražnju.

Tablica 5 - Tablica odabira prognoze potražnje. [2]

Metoda	t	D	F	Vrijeme pripreme
Prosjeci	2 do 30	uniformalna	kratko	kratko
Eksp. izglađivanje	5 do 10	uniformalna	kratko	kratko
Holt	10 do 20	trend	kratko srednje	srednje
Winters	barem prisutne dvije sezonske oscilacije	ciklična sezonalna	kratko srednje	srednje

6. ANALIZA PRAKTIČNIH PRIMJERA

U ovom poglavlju izrađena je analiza kapaciteta suprastrukture skladišta tvrtke Kineo tehne d.o.o. s prijedlozima povećanja iskorištenja. Analiza kapaciteta služi kao pregled mogućnosti skladišnog projektiranja gdje logistika pruža potporu veleprodajnom sustavu analizirajući i poboljšavajući regalnu suprastrukturu.

Osim skladišnih kapaciteta ovo poglavlje sadrži analizu rezultata dobivenih P modelom s promjenjivim periodima kojima se vrši izračun optimalnih zaliha, te analizu kvantitativnih metoda prognoze da bi se odredila najtočnija s obzirom na tip prodajnih podataka koji je prisutan kod prodaje robe navedene veleprodajne tvrtke.

Nadalje, uporabom P modela vrši se i usporedba optimalnih količina zaliha između P modela i ljudskog operatera s dugogodišnjim iskustvom u kontroli razine zaliha.

6.1 ANALIZA KAPACITETA SUPRASTRUKTURE SKLADIŠTA

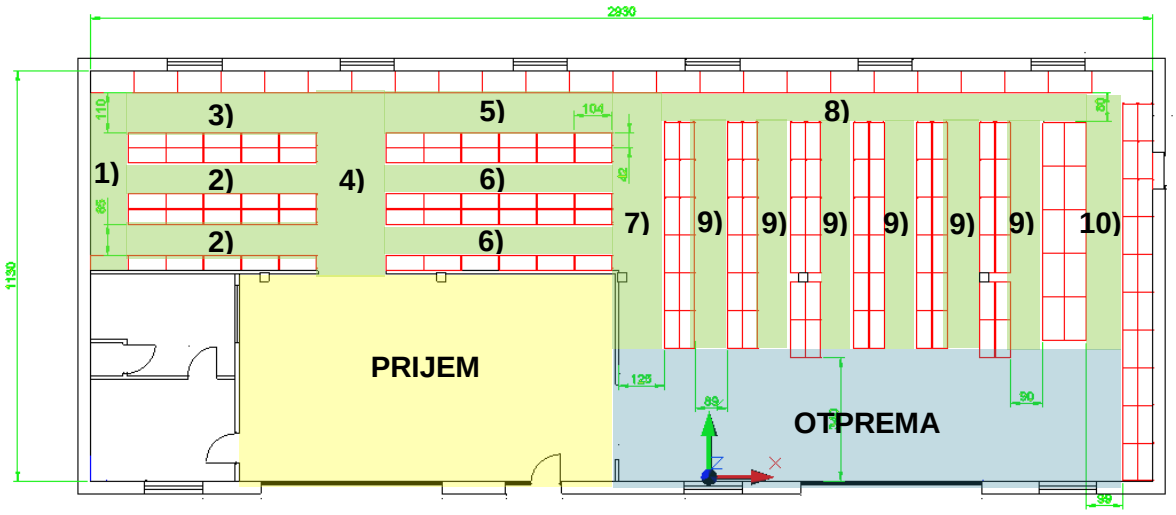
Kod analize iskoristivosti skladišnih kapaciteta treba uzeti u obzir dva elementa [12]:

1. Bruto skladišni kapacitet objekta;
2. Neto kapacitet suprastrukture skladišta (metode skladištenja, vrste regala ...).

Spomenute dvije varijable daju omjer ukupnog prostora koji je raspoloživ naspram prostora koji se koristi za pohranu zaliha na regale (obrađeno u 2.1 i 2.6). Da bi se optimizirao skladišni kapacitet treba imati saznanja o različitim mješavinama zaliha koje će se skladištiti u objektu te potrebnoj skladišnoj opremi. Bruto skladišni kapacitet objekta je prostor koji se sastoji od više prisutnih infrastrukturnih prostorija unutar objekta bez dodijeljenih funkcija kojemu će služiti. Neto kapacitet suprastrukture skladišta pokazuje korisnu iskoristivost za pohranu zaliha unutar skladišta.

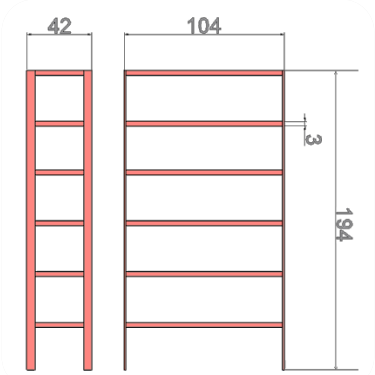
Korisna iskoristivost prostora skladišnog objekta varira ovisno o vrsti skladišnog objekta i onoga što je u njemu s obzirom na prisutne skladišne operacije. Suprastruktura sadrži regale i robu, dok je preostali prostor predviđen za prolaze, prostor za otpremu i prijem, u ovom primjeru koji se temelji na spomenutom stvarnom skladištu suprastruktura se izvodi prema regalima lake izvedbe koji imaju potrebne karakteristike za skladištenje gotovih proizvoda široke potrošnje. Valja uzeti u obzir i prostor između vrha regala i stropa objekta jer nije uobičajeno da se roba skladišti do stropa. Radi praktičnosti pristupa regalu on ne bi trebao biti veći od 2.5m. Slika 28 prikazuje izračun kvadrata na tlocrtu skladišnog objekta s trenutno postavljenom regalnom suprastrukturom.

Slika 28 će biti temelj prikaza izračuna iskoristivosti skladišnih kapaciteta za veleprodajno skladište.



Slika 28 - Tlocrt skladišnog objekta s suprastrukturom uzetog primjera. [1]

Izračun kapaciteta suprastrukture skladišnog objekta zavisi o vrsti skladišnih regala. U ovom primjeru uzeti su regali lake izvedbe prema stvarnoj primjeni u veleprodajnom skladištu koje je uzeto za prikaz praktičnog dijela rada. Slika 29 prikazuje karakteristike jedne konzole regala. Slika 28 prikazuje tlocrt skladišta prema kojemu se vrši izračun trenutačnih raspoloživih suprastrukturnih kapaciteta. **Tablica 6** kvantificira podatke.



Slika 29 - Karakteristike jedne konzole regala. [1]

Po tlocrtu objekta skladišta bruto kapacitet objekta iznosi 331,09 m^2 (od toga je 194,62 m^2 posvećeno zoni skladištenja). **Tablica 6** pokazuje izračun kvadrata regalne suprastrukture koja iznosi 88,38 m^2. Prema tome korisna iskoristivost skladišta za pohranu zaliha u ovom slučaju iznosi 26,89 % (omjer bruto i neto). Ovaj postotak se čini značajno mali no valja uzeti u obzir postojanost zona otpreme, prijema, prolaza i ureda koji služe za aktivnosti koje su neophodne za funkcioniranje skladišta.

Tablica 6 - Izračun ukupne kvadrature i kubika skladišne suprastrukture primjera. [1]

Regali (m^2)			
1)	1,04m*0,42m*148kom	=	64,65
2)	1,20m*0,60m*33kom	=	23,76
	Suma (m^2)	=	**88,38**

Prolazi (m^2)			
1)	1,04m*4,45m	=	4,63
2)	0,95m*5,20m*2kom	=	9,88
3)	1,10m*5,20m	=	5,72
4)	1,90m*4,90m	=	9,31
5)	1,10m*6,24m	=	6,87
6)	0,95m*6,24m*2kom	=	11,86
7)	1,25m*7,00m	=	8,75
8)	0,80*11,60	=	9,28
9)	0,90m*6,24m*6kom	=	33,7
10)	1,00m*6,24m	=	6,24
	Suma (m^2)	=	**106,24**

Ukupna kvadratura (m^2)	=	**194,62**
Ukupni kubici (m^3)	=	**486,55**

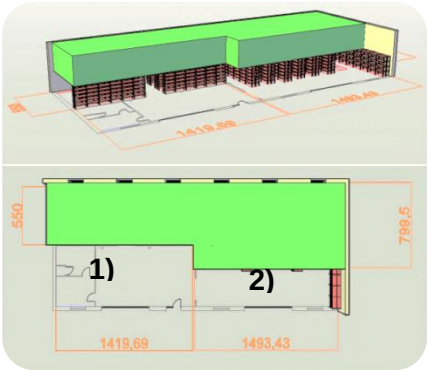
Omjer slobodnog prostora koji služi za prolaze u odnosu na regale ovom slučaju (zona predviđena za skladištenje) iznosi 55% (izračun u danjem tekstu).

Tablica 7 – Odnosi prisutnih zona u skladištu. [1]

88,38	m^2	27%	Regali
106,24	m^2	32%	Prolazi
49,64	m^2	15%	Otprema
45,2	m^2	14%	Kancelarije
41,63	m^2	13%	Prijem
331,09	m^2	100%	Bruto m^2 skladište

Tablica 7 prikazuje odnose prisutnih zona u skladištu. U daljnjoj analizi fokus će biti na zoni uskladištenja zaliha koja se sastoji od prostora regala i prolaza između regala.

Danji prostor za proširenje skladišne regalne suprastrukture je jedino moguć u visinu skladišta. Slika 30 prikazuje bruto raspoloživi neiskorišteni prostor unutar skladišta za zonu uskladištenja. S obzirom da je visina objekta pet metara dobiju se sljedeći podaci.



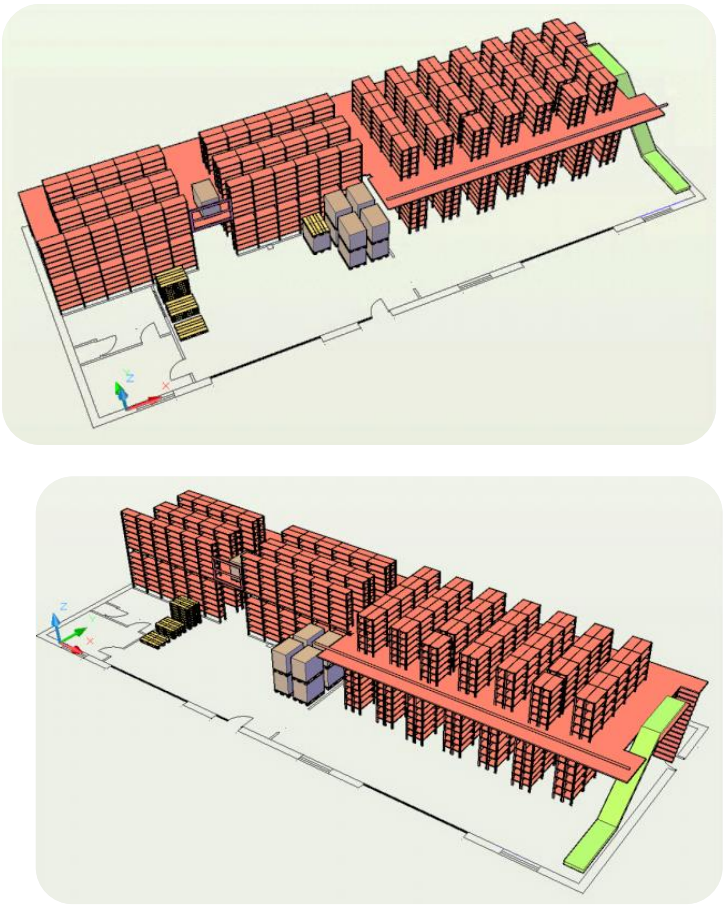
Slika 30 - Potencijalni prostor za skladištenje. [1]

Tablica 8 - Izračun raspoloživih kubika ne iskorištenog skladišnog prostora. [1]

Prostor za nadogradnju (m^3)			
1)	2,5*5,5*14,2	=	195,25
2)	2,5*8*14,9	=	298
	Suma (m^3)	**=**	**493,25**
	Aproksimirana iskoristivost	=	45%
	Predviđeni regalni kubici (m^3)	**=**	**221,96**

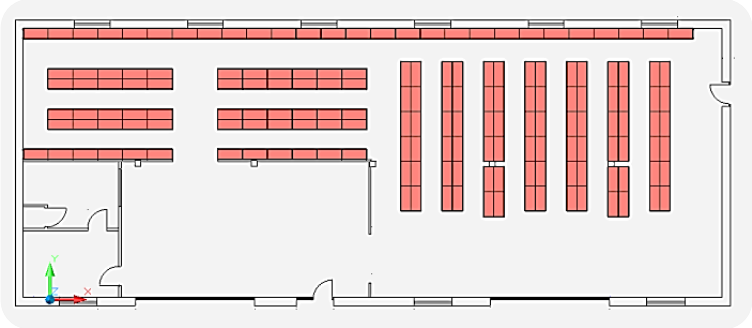
Analizom neiskorištenog dijela skladišta podaci pokazuju da se može procijeniti povećanje kapacitet skladišta za 222 m^3 ako se etažira postojeću regalnu suprastrukturu.

Nadograđivanjem suprastrukture prizemni dio uglavnom ostaje isti, s time da je jedan cijeli regal morao biti maknut zbog karakteristika etažne konstrukcije. Zbog uporabe stepeništa i konvejera desni dio skladišta je izgubio dio regalnog prostora. U lijevom dijelu skladišta omogućen je pristup paletama na etažni dio konstrukcije zbog funkcije pohrane zaliha.



Slika 31 - Prikaz predloženog rješenja etažiranog skladišta. [1]

Danjim izračunom prizemnog dijela etažne konstrukcije, koristeći karakteristike regala koje čine suprastrukturu dobije se kubični prostor ostvaren za potrebe skladištenja zaliha.



Slika 32 - Izmjene prizemne regalne suprastrukture. [1]

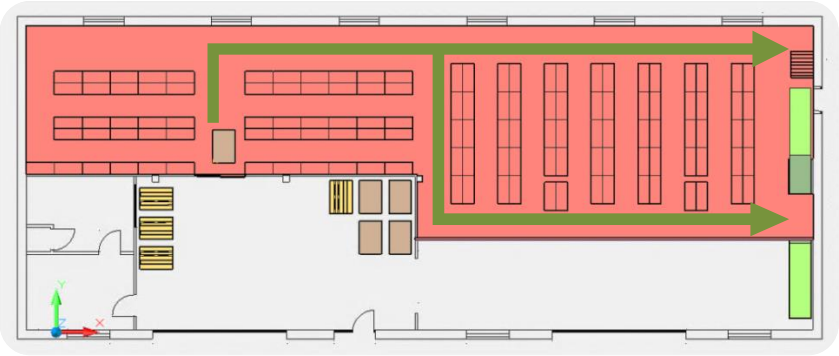
U sljedećem koraku je prikazan izračun ukupnih raspoloživih kubika prizemnog dijela etažne suprastrukture.

Tablica 9 - Izračun raspoloživih kubika prizemnog dijela etažne suprastrukture. [1]

KUBICI KONZOLE REGALA		
Visina stupa:	1,94	[m]
Širina stupa:	1,04	[m]
Dubina stupa:	0,42	[m]
Prostor Iznad regala:	0,5	[m]
Ukupni kubici:	**1,07**	**[m^3]**
KUBICI ISPUNE REGALA		
Visina police:	0,03	[m]
Širina police:	1,04	[m]
Dubina police:	0,42	[m]
Broj ispuna po stupu:	6	[kom]
Kubici ispune:	**0,08**	**[m^3]**
ISKORISTIVOST KONZOLE		
Ukupni kubici konzole:	**0,99**	[m^3]
KUBICI PRIZEMNIH REGALA		
Broj konzola regala	167	[kom]
Kubici prizemnih regala:	**165,33**	**[m^3]**

Nakon izračuna prizemnog dijela etažne regalne suprastrukture slijedi izračun etažnog dijela.

Etažni dio zbog smanjenja podnog prostora gubi najduži pozadinski regal gdje se sada nalazi glavni prolaz za kretanje, krajnji desni bočni regal gdje je sada stepenište i konvejer te prednji dio desne polovice regala radi omogućavanja kretanja prilikom komisioniranja Ovakav etažni sistem pogoduje zoniranju zbog odvojenosti razina ragala kojima se može pristupiti samo s pripadajuće etaže, također, veći broj regala utjeće i na dijeljenje lokacija na zone zbog manjka uporabljivih simbola koji će s emoći koristiti za imenovanje regala. Nadalje, zbog sigurnosti konstrukcije valja uzeti u obzir i da na gornjim etažama treba skladištiti lakšu robu.



Slika 33 - Izmjene etažne regalne suprastrukture. [1]

Tablica 10 prikazuje izračun ukupnih raspoloživih kubika etažnog dijela nove suprastrukture.

Tablica 10 - Izračun raspoloživih kubika etažnog dijela suprastrukture. [1]

KUBICI KONZOLE REGALA		
Visina stupa:	1,94	[m]
Širina stupa:	1,04	[m]
Dubina stupa:	0,42	[m]
Prostor Iznad regala:	0,5	[m]
Ukupni kubici:	1,07	[m^3]
KUBICI ISPUNE REGALA		
Visina police:	0,03	[m]
Širina police:	1,04	[m]
Dubina police:	0,42	[m]
Broj ispuna po stupu:	6	[kom]
Kubici ispune:	0,08	[m^3]
ISKORISTIVOST KONZOLE		
Ukupni kubici konzole:	**0,99**	[m^3]
KUBICI ETAŽNIH REGALA		
Broj konzola regala	140	[kom]
Ukupni kubici regala:	**138,69**	**[m^3]**

Usporedbom ukupnih m^3 regala donjeg i gornjeg dijela etažnog skladišta vidi se da je došlo do povećanja od ~ 0,54% iskoristivog prostora za skladištenje zaliha. Usporedbom prvobitnog izgleda suprastrukture gdje je bilo 204,38 m^3 iskoristivog regalnog prostora (umanjeno s 220,95 zbog ispuna regala koje iznose 0.075% konzole) na 304,02 m^3 iskoristivog regalnog prostora (165,33 m^3 prizemne polovice, te 138,69 m^3 etažnog dijela) etažiranjem regala. Povećanje iskoristivog regalnog prostora iznosi 33% naspram početnog stanja. Dok je prvobitno bila prizemna regalna iskoristivost 204,38 m^3 a naknadno je iznosila 165,33 m^3, što je smanjenje od 20% na prizemnoj razini radi promjene suprastrukture zbog konvejera i stepenica.

S obzirom da je ukupni bruto raspoloživi prostor skladišog objekta 1695,45 m^3, a prva regalna etaža u izvornoj izvedbi prije optimizacije imala 204,38 m^3, dok sadašnja ukupna regalna suprastruktura ima 304,02 m^3, kubična iskorištenost skladišnog objekta za uskladištenje zalihe je povećana s 12% na 18%.

6.2 ANALIZA P MODELA

Na sljedećim analizama izvršiti će se izračun optimalnih zaliha P metodom za 12 mjeseci unutar godine. Analiza P metode će se bazirati na tri perioda, period od 12, 4 i 2 mjeseca. Usporedbom rezultata biti će jasnije kako vremenski razmaci perioda povijesnih podataka utječu na točnost rezultata optimizacije. Vrijeme između narudžbi je tri radna tjedna dok vrijeme isporuke pet dana, za stopu usluge od 99,9% z je 2,33.

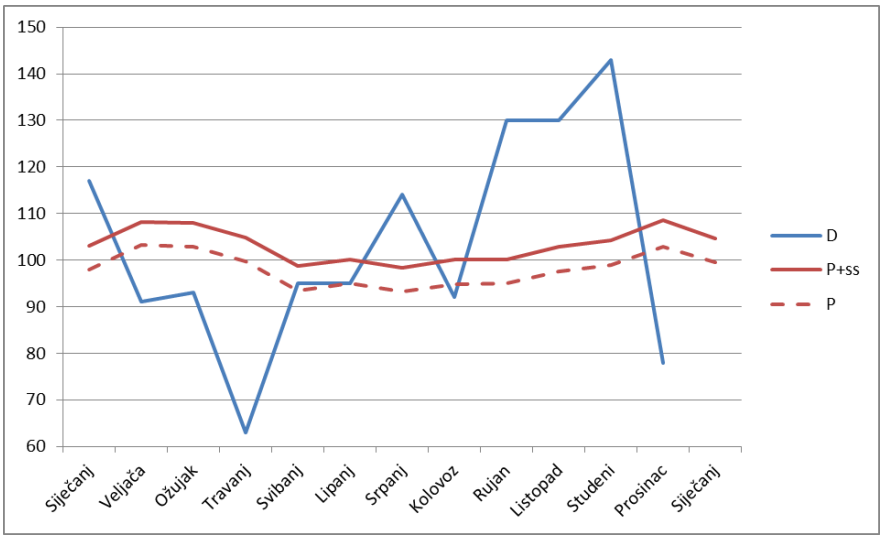
- **Izračun optimalnih zaliha s periodom od 12 mjeseci**

Tablica 11 prikazuje izračun optimalnih zaliha P modelom za period od 12 mjeseci. S obzirom na potražnju od godine dana optimalna količina zalihe ima tendenciju variranja oko cjelokupnog prosjeka perioda povijesnih podataka uzetih za izračun. Uzimanje većeg perioda povijesnih podataka zahtijeva znatno više povijesnih podataka što povećava opseg posla kod izrade izračuna.

Tablica 11 - Primjer izračuna optimalnih zaliha P modelom za period od 12 mjeseci. [1]

Mjesec	Potražnja	Radni dani	$\bar{d}$ (12 mj.)	$\bar{d}$ (dan)	$(d-\bar{d})^2$	σ (12 mj.)	σ (dan)	Q
Veljača	**95**	**20**						
Ožujak	**130**	**22**						
Travanj	**143**	**21**						
Svibanj	**78**	**20**						
Lipanj	**117**	**19**						
Srpanj	**91**	**23**						
Kolovoz	**93**	**20**						
Rujan	**95**	**22**						
Listopad	**114**	**21**						
Studeni	**92**	**21**						
Prosinac	**130**	**22**		4,90			0,50	
Siječanj	117	20	107,92	5,16	82,51	10,12	0,48	103
Veljača	91	20	107,58	5,14	275,01	10,12	0,48	**108**
Ožujak	93	22	104,50	5,00	132,25	10,12	0,48	**108**
Travanj	63	21	97,83	4,68	1213,36	10,12	0,50	**105**
Svibanj	95	20	99,25	4,75	18,06	10,12	0,50	**99**
Lipanj	95	19	97,42	4,66	5,84	10,12	0,50	**100**
Srpanj	114	23	99,33	4,75	215,11	10,12	0,49	**98**
Kolovoz	92	20	99,25	4,75	52,56	10,12	0,50	**100**
Rujan	130	22	102,17	4,88	774,69	10,12	0,50	**100**
Listopad	130	21	103,50	4,95	702,25	10,12	0,51	**103**
Studeni	143	21	107,75	5,15	1242,56	10,12	0,52	**104**
Prosinac	78	22	103,42	4,94	646,01	10,12	0,55	**108**
Siječanj								**105**
	T (dana)=	15	L (dana) =	5	z =	2,33		

Dijagram 14 prikazuje oblik krivulje optimalnih zaliha po P modelu s bazom perioda od 12 mjeseci gdje je jasno vidljivo da veći broj perioda negativno utječe na prilagođavanje optimizacije na promjene u potražnji što ju čini netočnom.



Dijagram 14 - Dijagram izračuna optimalnih zaliha P modelom za period od 12 mjeseci. [1]

Tablica 12 prikazuje izračun grešaka P modela za period od 12 mjeseci gdje je MAPE[6] u iznosu vrijednosti od 20%. Korištenje velikog broja perioda za izračun omogućava zadovoljenje potražnje koja je ispod globalnog prosjeka prodaje dok ne omogućava zadovoljenje povećanja potražnje zbog tendencije izračuna optimalnih zaliha oko ukupnog prosjeka potražnje.

Tablica 12 - Izračun pogreške P modela perioda 12 mjeseci i stvarne potražnje. [1]

				P model (12 mjeseci)			
Mjesec	**D**	**P + ss**	**P**	**e**	**e^2**	**|e|**	**MAPE (%)**
Siječanj	117	**103**	98	14	196	14,08	13,59
Veljača	91	**108**	103	-17	296,90	17,23	15,92
Ožujak	93	**108**	103	-15	221,77	14,89	13,80
Travanj	63	**105**	100	-42	1757,28	41,92	39,95
Svibanj	95	**99**	94	-4	13,82	3,72	3,77
Lipanj	95	**100**	95	-5	25,89	5,09	5,08
Srpanj	114	**98**	93	16	245,71	15,68	15,94
Kolovoz	92	**100**	95	-8	65,74	8,11	8,10
Rujan	130	**100**	95	30	892,13	29,87	29,83
Listopad	130	**103**	98	27	733,78	27,09	26,32
Studeni	143	**104**	99	39	1497,26	38,69	37,10
Prosinac	78	**108**	103	-30	929,30	30,48	28,10
Siječanj		**105**	100				
∑				3,89	6875,58	246,77	
P model	**MAE:**	21		**RMSE:**	24	**MAPE** (%):	20

[6] 5.1 - Prosječna postotna apsolutna pogreška

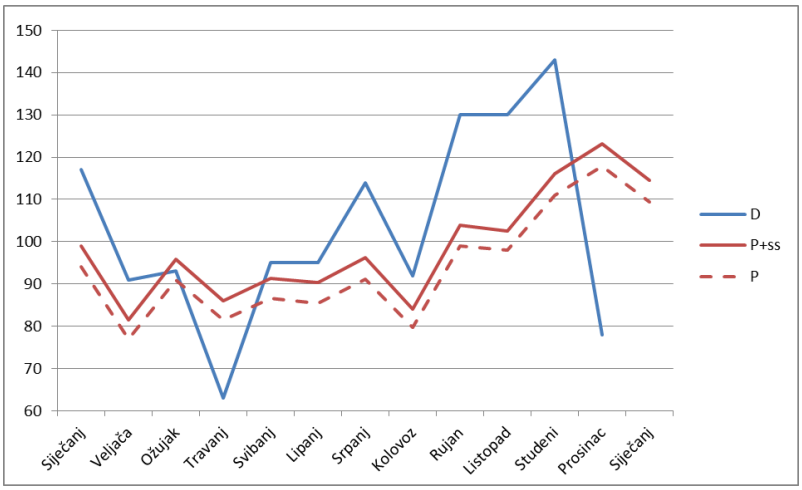
- **Izračun optimalnih zaliha s periodom od 4 mjeseca**

Tablica 13 prikazuje izračun optimalnih zaliha P modelom za period od 4 mjeseca. Optimalna količina zalihe ima znatno bolju reakciju na promjenu u potražnji od prijašnje gdje je period od 12 mjeseci. Krivulja optimalnih zaliha varira oko prosjeka no ovaj puta pokazuje i globalni trend s prilagodbom na individualne promjene u potražnji od mjeseca do mjeseca.

Tablica 13 - Primjer izračuna optimalnih zaliha P modelom za period od 4 mjeseca. [1]

Mjesec	Potražnja	Radni dani	$\bar{d}$ (4 mj.)	$\bar{d}$ (dan)	$(d-\bar{d})^2$	σ (4 mj.)	σ (dan)	Q
Listopad	**35**	**21**						
Studeni	**98**	**21**						
Prosinac	**58**	**22**		5			0,46	
Siječanj	117	20	77	4	1600,00	8,77	0,44	99
Veljača	91	20	91	5	0,00	9,17	0,46	**82**
Ožujak	93	22	89,75	4	10,56	9,27	0,42	**96**
Travanj	63	21	91	4	784,00	9,34	0,44	**86**
Svibanj	95	20	85,5	4	90,25	9,45	0,47	**91**
Lipanj	95	19	86,5	5	72,25	9,39	0,49	**90**
Srpanj	114	23	91,75	4	495,06	9,42	0,41	**96**
Kolovoz	92	20	99	5	49,00	9,52	0,48	**84**
Rujan	130	22	107,75	5	495,06	9,81	0,45	**104**
Listopad	130	21	116,5	6	182,25	10,19	0,49	**103**
Studeni	143	21	123,75	6	370,56	10,57	0,50	**116**
Prosinac	78	22	120,25	5	1785,06	10,82	0,49	**123**
Siječanj								**114**
	T (dana)=	15	L (dana) =	5	z =	2,33		

Dijagram 15 prikazuje oblik krivulje optimalnih zaliha po P modelu s bazom perioda od 4 mjeseca gdje je jasno vidljivo poboljšanje prilagodbe metode promjenama u potražnji.



Dijagram 15 - Dijagram izračuna optimalnih zaliha P modelom za period od 4 mjeseca. [1]

Tablica 14 prikazuje izračun grešaka P modela za period od 4 mjeseca gdje je MAPE u iznosu vrijednosti od 17%. Korištenje manjeg broja perioda za izračun omogućava smanjenje potrebnih zaliha u mjesecima gdje je prisutan pad potražnje. Očita je bolja prilagodba kod povećanja potražnje no i dalje se vidi zaostajanje predviđanja na naglo povećanje potražnje.

Tablica 14 - Izračun pogreške P modela perioda 4 mjeseca i stvarne potražnje. [1]

				P model (4 mjeseca)			
Mjesec	**D**	**P + ss**	**P**	**e**	**e^2**	**|e|**	**MAPE (%)**
Siječanj	117	**99**	94	18	324	18	18,18
Veljača	91	**82**	77	9	88,89	9,42	11,56
Ožujak	93	**96**	91	-3	7,70	2,77	2,90
Travanj	63	**86**	82	-23	528,13	22,98	26,73
Svibanj	95	**91**	87	4	13,69	3,70	4,05
Lipanj	95	**90**	86	5	20,94	4,57	5,06
Srpanj	114	**96**	91	18	316,74	17,79	18,50
Kolovoz	92	**84**	80	8	63,21	7,95	9,46
Rujan	130	**104**	99	26	678,00	26,03	25,05
Listopad	130	**103**	98	27	750,68	27,39	26,70
Studeni	143	**116**	111	27	728,64	26,99	23,27
Prosinac	78	**123**	118	-45	2034,23	45,10	36,64
Siječanj		**114**	109				
∑				71,02	5554,89	212,74	
P model	**MAE:**	18		**RMSE:**	22	**MAPE** (%):	17

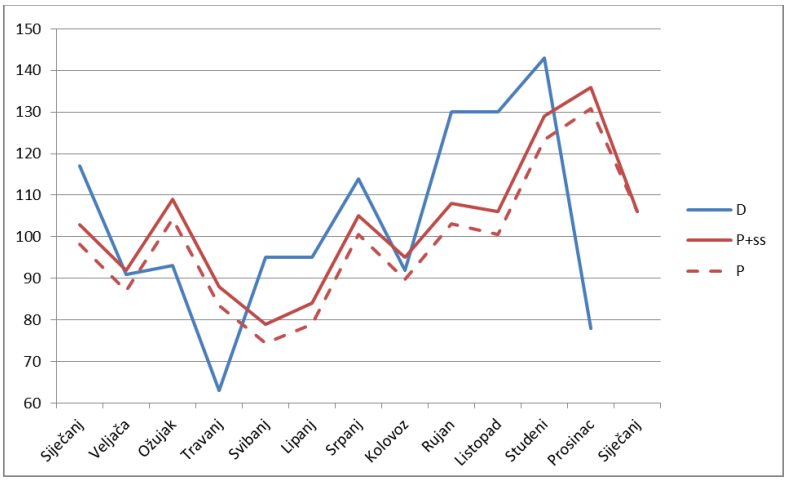
- **Izračun optimalnih zaliha s periodom od 2 mjeseca**

Tablica 15 - Primjer izračuna optimalnih zaliha P modelom za period od 2 mjeseca. [1]

Mjesec	Potražnja	Radni dani	$\bar{d}$ (2 mj.)	$\bar{d}$ (dan)	$(d-\bar{d})^2$	σ (2 mj.)	σ (dan)	Q
Prosinac	**58**	**22**		5			0,48	
Siječanj	117	20	87,5	4	870,25	9,35	0,47	103
Veljača	91	20	104	5	169,00	9,79	0,49	**92**
Ožujak	93	22	92	4	1,00	9,90	0,45	**109**
Travanj	63	21	78	4	225,00	9,22	0,44	**88**
Svibanj	95	20	79	4	256,00	8,86	0,44	**79**
Lipanj	95	19	95	5	0,00	9,33	0,49	**84**
Srpanj	114	23	104,5	5	90,25	9,99	0,43	**105**
Kolovoz	92	20	103	5	121,00	10,19	0,51	**95**
Rujan	130	22	111	5	361,00	10,34	0,47	**108**
Listopad	130	21	130	6	0,00	10,98	0,52	**106**
Studeni	143	21	136,5	7	42,25	11,54	0,55	**129**
Prosinac	78	22	110,5	5	1056,25	11,11	0,51	**136**
Siječanj								**106**
	T (dana)=	15	L (dana) =	5	z =	2,33		

Tablica 15 prikazuje izračun optimalnih zaliha za period od 2 mjeseca. Optimalna količina zalihe pokazuje više individualnu reakciju na promjenu u potražnji od prijašnje metode. Krivulja optimalnih zaliha više ne varira oko prosjeka dok slijedi trend u potražnji.

Dijagram 16 prikazuje oblik krivulje optimalnih zaliha po P modelu s bazom perioda od 2 mjeseca gdje je jasno vidljivo najtočnije poboljšanje prilagodbe metode promjenama u potražnji. Vidljivo je da se kod malog perioda povijesnih podataka krivulja lako izobliči jer nije toliko stabilna kod naglog pada potražnje što utječe na sljedeći mjesec (travanj -svibanj).



Dijagram 16 - Dijagram izračuna optimalnih zaliha P modelom za period od 2 mjeseca. [1]

Tablica 16 prikazuje izračun grešaka P modela za period od 4 mjeseca gdje je MAPE u iznosu vrijednosti od 17%. Korištenje manjeg broja perioda za izračun omogućava smanjenje potrebnih zaliha u mjesecima gdje je prisutan pad potražnje. Očita je bolja prilagodba kod povećanja potražnje i bolja prilagodba na naglo povećanje potražnje unutar podataka.

Tablica 16 - Izračun pogreške P modela perioda 2 mjeseca i stvarne potražnje. [1]

				P model (2 mjeseca)			
Mjesec	**D**	**P + ss**	**P**	**e**	**e^2**	**|e|**	**MAPE (%)**
Siječanj	117	103	98	14	196	14	13,59
Veljača	91	**92**	87	-1	1	1	1,09
Ožujak	93	**109**	104	-16	256	16	14,68
Travanj	63	**88**	83	-25	625	25	28,41
Svibanj	95	**79**	74	16	256	16	20,25
Lipanj	95	**84**	79	11	121	11	13,10
Srpanj	114	**105**	100	9	81	9	8,57
Kolovoz	92	**95**	90	-3	9	3	3,16
Rujan	130	**108**	103	22	484	22	20,37
Listopad	130	**106**	101	24	576	24	22,64
Studeni	143	**129**	123	14	196	14	10,85
Prosinac	78	**136**	131	-58	3364	58	42,65
Siječanj		**106**	106				
∑				7,00	6165,00	213,00	
P model	**MAE:**	18		**RMSE:**	23	**MAPE** (%):	17

- **Usporedba utjecaja različitosti perioda na rezultate P modela**

Usporedbom navedenih metoda za podatke potražnje koji su upotrijebljeni u svim izračunima, P model s periodom od 2 mjeseca je dao rezultate s najmanje grešaka s obzirom na ostale periode.

Dijagram 17 daje pregled utjecaja perioda na krivulju optimalnih zaliha. Period od 4 i 2 mjeseca daju isto vrijednost pogreške što je vidljivo u prije priloženim tablicama. Razlika je što u manjem periodu od 2 mjeseca optimizacija ima bolju osjetljivost na nagle i znatne promjene u potražnji, što je vidljivo u mjesecima rujan-listopad-studeni. Takva osjetljivost ima i svoje mane gdje nagli pad potražnje (koji ne odražava stalan pad no ne regularnu oscilaciju) negativno utječe na sljedeći mjesec kojemu se ponovno stabilizira potražnja, što je vidljivo u mjesecima travanj-svibanj.



Dijagram 17 - Dijagram potražnje i optimalnih zaliha za period od 12, 4 i 2 mjeseca. [1]

Ovi podaci su bitni i za pod poglavlje 0 gdje će se usporediti izračun optimalnih nivoa zaliha i predviđanja potražnje.

Da bi na mogli usporediti kretanje zaliha kroz skladište, tj. da bi usporedili dali politika vođenja vrsti i razine zaliha rezultira smanjenjem ili povećanjem protoka zaliha služi koeficijent obrtaja zaliha. Koeficijent obrtaja zaliha je još jedan alat pomoću kojeg se može kvantificirati i usporediti obrtajne vrijednosti zaliha unutar određenih vremenskih perioda. Bitan aspekt kod zaliha je i taj koliko se zaradi na prodaji zaliha što utječe na potrebnu količinu prodaje zaliha da bi se omogućilo pokrivanje troška i ostvarivanje zarade.

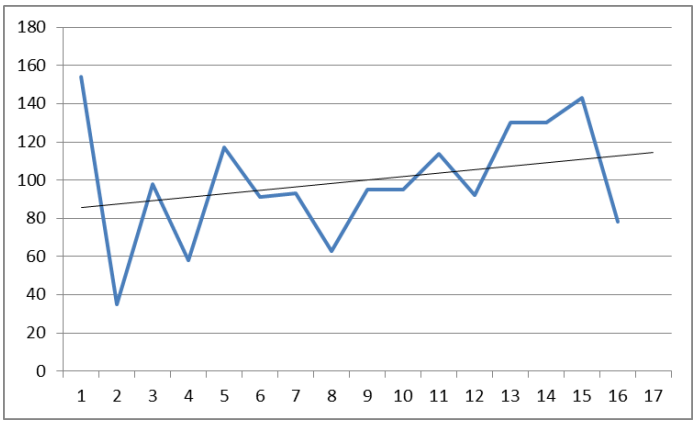
6.3 ANALIZA KVANTITATIVNIH METODA PROGNOZE

Sve kvantitativne metode prognoze potražnje iz pod poglavlja 5 će se analizirati na istom setu podataka uzetih iz prakse [1]. Obradom podataka o potražnji i analizom grešaka (metode obrađene u pod poglavlju 5.1) uvidjeti će se iskoristivost metoda za praktičnu stvarnu primjenu.

Tablica 17 - Podaci potražnje za izračune. [1]

Period	D
1	**154**
2	35
3	98
4	58
5	117
6	91
7	93
8	63
9	95
10	95
11	114
12	92
13	130
14	130
15	143
16	78

Tablica 17 prikazuje podatke na kojima će se vršiti izračuni kvantitativnih metoda prognoze potražnje. Podaci se sastoje od 12 mjeseci prodajnih podacima s 4 mjeseca na kojima će se vršiti izračun početnih vrijednosti za godinu u izračunu. Dijagram 18 ilustrira podatke potražnje, vidljivo je da uzeti podaci imaju znatne oscilacije upotražnji, te da je prisutan globalni trend rasta potražnje.



Dijagram 18 - Dijagram potražnje za primjere izračuna prognoza. [1]

- **Pomični prosjeci**

Tablica 18 - Izračun pomičnog prosjeka za 3 i 5 perioda. [1]

t	D	F3	e	e^2	|e|	***MAPE*** (%)
1	154					
2	35					
3	98					
4	58	96	37,67	1418,78	37,67	39,37
5	117	64	-53,33	2844,44	53,33	83,77
6	91	91	0,00	0,00	0,00	0,00
7	93	89	-4,33	18,78	4,33	4,89
8	63	100	37,33	1393,78	37,33	37,21
9	95	82	-12,67	160,44	12,67	15,38
10	95	84	-11,33	128,44	11,33	13,55
11	114	84	-29,67	880,11	29,67	35,18
12	92	101	9,33	87,11	9,33	9,21
13	130	100	-29,67	880,11	29,67	29,57
14	130	112	-18,00	324,00	18,00	16,07
15	143	117	-25,67	658,78	25,67	21,88
16	78	134	56,33	3173,44	56,33	41,94
17		**117**				
∑			-44,00	11968,22	325,33	
***MAE*:**	25	***RMSE*:**	30	***MAPE*** (%):	27	

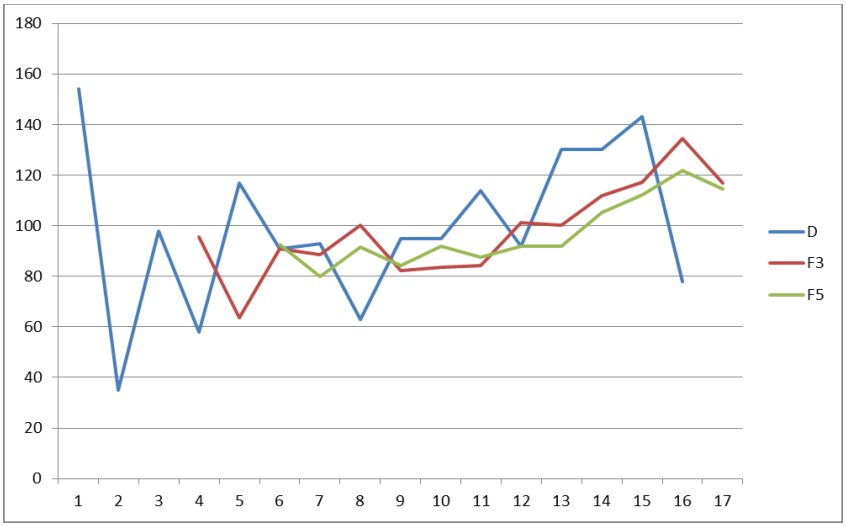
t	D	F5	e	e^2	|e|	***MAPE*** (%)
1	154					
2	35					
3	98					
4	58					
5	117					
6	91	92	1,40	1,96	1,40	1,52
7	93	80	-13,20	174,24	13,20	16,54
8	63	91	28,40	806,56	28,40	31,07
9	95	84	-10,60	112,36	10,60	12,56
10	95	92	-3,20	10,24	3,20	3,49
11	114	87	-26,60	707,56	26,60	30,43
12	92	92	0,00	0,00	0,00	0,00
13	130	92	-38,20	1459,24	38,20	41,61
14	130	105	-24,80	615,04	24,80	23,57
15	143	112	-30,80	948,64	30,80	27,45
16	78	122	43,80	1918,44	43,80	35,96
17		**115**				
∑			-73,80	6754,28	221,00	
***MAE*:**	20	***RMSE*:**	25	***MAPE*** (%):	20	

PP_3 se odnosi na pomične prosjeke unutar tri perioda. Kod ove metode treba uzeti u obzir da se kod pomičnih prosjeka, kako svaka nova vrijednost dolazećeg perioda postane dostupna,

predviđanje ažurira dodavanjem nove vrijednosti dok se istovremeno izostavlja najstarija vrijednost, što daje novi i drugačiji prosjek.

Tablica 18 prikazuje razlike u rezultatima prognoze potražnje metodom pomičnih prosjeka kod promjene perioda.

Kod korištenja pomičnog prosjeka može se uzeti koliko god se želi perioda. Pri odabiru količine perioda koji će se koristiti kod predviđanja, operater treba uzeti u obzir da se kod povećavanja perioda smanjuje osjetljivost te tehnike. Dijagram 19 ilustrira smanjenje reakcije prognoze na promjenu potražnje povećavanjem količine perioda izračuna.



Dijagram 19 - Dijagram pomičnih prosjeka za 3 i 5 perioda. [1]

Operater mora odvagati trošak spore reakcije na promjene potražnje unutar podataka naspram troška prognoze koja reagira na nasumične varijacije. Pregled grešaka prognoze potražnje, može pomoći u tom odabiru.

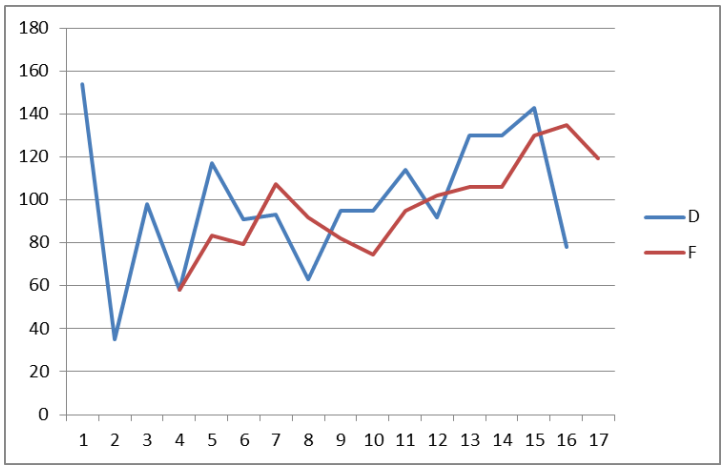
Prednosti pomičnih prosjeka je da se lako izračunava i lako razumije. Nepogodnost ove tehnike je da se sve vrijednosti teže jednako. Na primjer u 12 perioda pomični prosjek teži svaku vrijednost 1/12. Tako da najstarija vrijednost ima istu važnost kao i najnovija.

- **Težinski prosjek**

Tablica 19 - Izračun težinskog prosjeka. [1]

W1 =	0,36508	W2 =	0,63492	W3 =	0	
t	**D**	**F** (TP)	**e**	**e^2**	**|e|**	***MAPE*** (%)
1	154					
2	35					
3	98					
4	58	58	0,00	0,00	0,00	0,00
5	117	83	-33,60	1129,18	33,60	40,29
6	91	80	-11,46	131,34	11,46	14,41
7	93	108	14,51	210,48	14,51	13,49
8	63	92	28,73	825,42	28,73	31,32
9	95	82	-12,95	167,77	12,95	15,79
10	95	75	-20,32	412,80	20,32	27,21
11	114	95	-19,00	361,00	19,00	20,00
12	92	102	9,94	98,73	9,94	9,75
13	130	106	-24,03	577,53	24,03	22,68
14	130	106	-24,13	582,11	24,13	22,79
15	143	130	-13,00	169,00	13,00	10,00
16	78	135	56,75	3220,11	56,75	42,11
17		**119**				
∑			-48,57	7885,46	268,41	
MAE:	21	***RMSE***:	25	***MAPE*** (%):	21	

Tablica 19 izražava vrijednosti dobivene prognozom potražnje metodom težinskog prosjeka. U ovom primjeru vrijednost varijable w3 koja je vezana za najnoviji podatak je jednaka nuli, optimalna vrijednost ukazuje da ne dolazi do umanjenja zadnje vrijednosti. Dijagram 19 ilustrira prognozu potražnje dobivenu metodom težinskih prosjeka.



Dijagram 20 - Dijagram težinskog prosjeka za 3 perioda. [1]

- **Eksponencijalno izglađivanje**

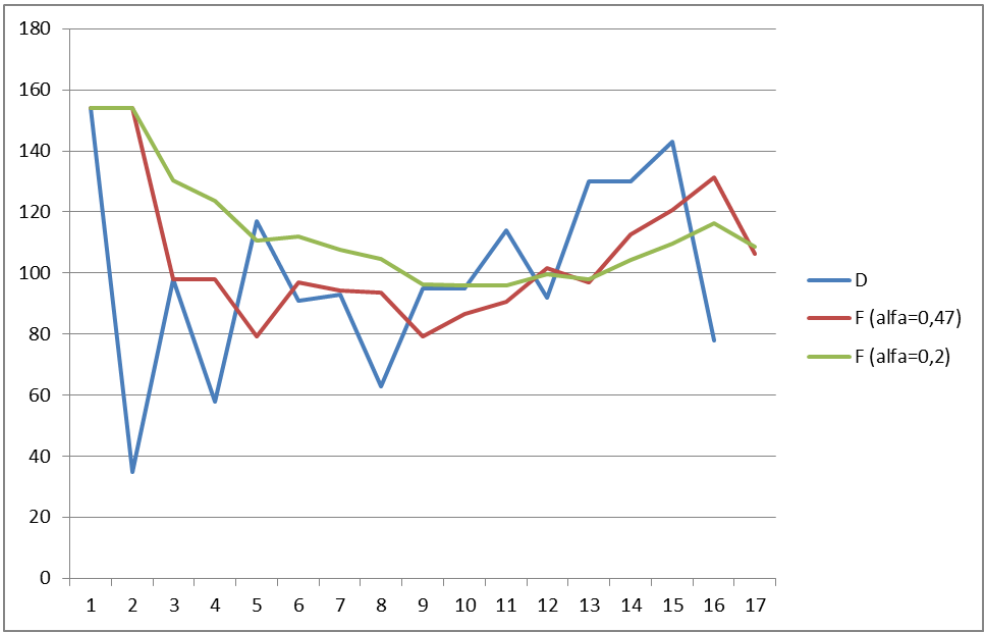
Tablica 20 - Izračun eksponencijalnog izglađivanja. [1]

alfa =	0,47059					
t	**D**	**F**	**e**	**e^2**	**|e|**	***MAPE*** (%)
1	**154**	**154**				
2	35	154	119,00	14161,00	119,00	77,27
3	98	98	0,00	0,00	0,00	0,00
4	58	98	40,00	1600,00	40,00	40,82
5	117	79	-37,82	1430,62	37,82	47,77
6	91	97	5,98	35,71	5,98	6,16
7	93	94	1,16	1,35	1,16	1,24
8	63	94	30,62	937,34	30,62	32,70
9	95	79	-15,79	249,37	15,79	19,94
10	95	87	-8,36	69,89	8,36	9,65
11	114	91	-23,43	548,78	23,43	25,86
12	92	102	9,60	92,12	9,60	9,45
13	130	97	-32,92	1083,64	32,92	33,91
14	130	113	-17,43	303,72	17,43	15,48
15	143	121	-22,23	494,01	22,23	18,40
16	78	131	53,23	2833,76	53,23	40,56
17		**106**				
∑			101,61	23841,32	417,56	
***MAE*:**	28	***RMSE*:**	40	***MAPE*** (%):	25	

alfa =	0,2					
t	**D**	**F**	**e**	**e^2**	**|e|**	***MAPE*** (%)
1	**154**	**154**				
2	35	154	119,00	14161,00	119,00	77,27
3	98	130	32,20	1036,84	32,20	24,73
4	58	124	65,76	4324,38	65,76	53,14
5	117	111	-6,39	40,86	6,39	5,78
6	91	112	20,89	436,24	20,89	18,67
7	93	108	14,71	216,36	14,71	13,66
8	63	105	41,77	1744,51	41,77	39,87
9	95	96	1,41	2,00	1,41	1,47
10	95	96	1,13	1,28	1,13	1,18
11	114	96	-18,10	327,43	18,10	18,87
12	92	100	7,52	56,61	7,52	7,56
13	130	98	-31,98	1022,78	31,98	32,63
14	130	104	-25,58	654,58	25,58	24,50
15	143	110	-33,47	1120,09	33,47	30,56
16	78	116	38,23	1461,21	38,23	32,89
17		**109**				
∑			227,10	26606,16	458,14	
***MAE*:**	31	***RMSE*:**	42	***MAPE*** (%):	26	

Tablica 20 prikazuje vrijednosti prognoza potražnje dobivene metodom eksponencijalnog izglađivanja s različitim alfa vrijednostima. U ovom primjeru optimalna vrijednost alfe se pokazala 0,47, MAPE iznosi 25% što je dosta visok postotak greške.

Dijagram 21 pokazuje prognozu potražnje sa drugačijim α vrijednostima. Niža α vrijednost daje prognozu koja vidljivo sporije reagira ne promjenu potražnje, dok viša α vrijednost koja je optimalna za podatke iz primjera daje krivulju predviđanja koja puno bolje prati potražnju.



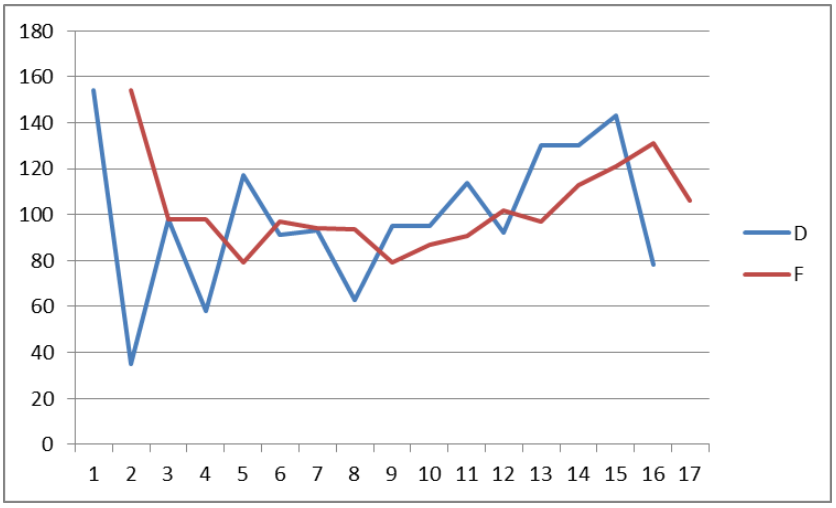
Dijagram 21 - Dijagram eksponencijalnog izglađivanja. [1]

- **Dvostruko eksponencijalno izglađivanje**

Tablica 21 - Izračun Holt metode. [1]

Level (alpha):	0,4705874		Trend (beta):	0			
t	**D**	***Level***	***Trend***	**F**	**e**	**e^2**	**|e|**	***MAPE*** (%)
1	**154**	**154,00**	0,00					
2	35	98,00	0,00	154	119,00	14161,00	119,00	77,27
3	98	98,00	0,00	98	0,00	0,00	0,00	0,00
4	58	79,18	0,00	98	40,00	1600,00	40,00	40,82
5	117	96,98	0,00	79	-37,82	1430,61	37,82	47,77
6	91	94,16	0,00	97	5,98	35,71	5,98	6,16
7	93	93,62	0,00	94	1,16	1,35	1,16	1,24
8	63	79,21	0,00	94	30,62	937,34	30,62	32,70
9	95	86,64	0,00	79	-15,79	249,37	15,79	19,94
10	95	90,57	0,00	87	-8,36	69,89	8,36	9,65
11	114	101,60	0,00	91	-23,43	548,78	23,43	25,86
12	92	97,08	0,00	102	9,60	92,12	9,60	9,45
13	130	112,57	0,00	97	-32,92	1083,64	32,92	33,91
14	130	120,77	0,00	113	-17,43	303,72	17,43	15,48
15	143	131,23	0,00	121	-22,23	494,01	22,23	18,40
16	78	106,18	0,00	131	53,23	2833,76	53,23	40,56
17				**106**				
∑					101,61	23841,32	417,56	
		MAE:	28	***RMSE***:	40	***MAPE***:	25	

Tablica 21 prikazuje vrijednosti prognoza potražnje dobivene Holt metodom s različitim optimalnim alfa i beta vrijednostima. Dijagram 22 prikazuje stvarnu potražnju i predviđanje potražnje dobivenu Holt metodom.

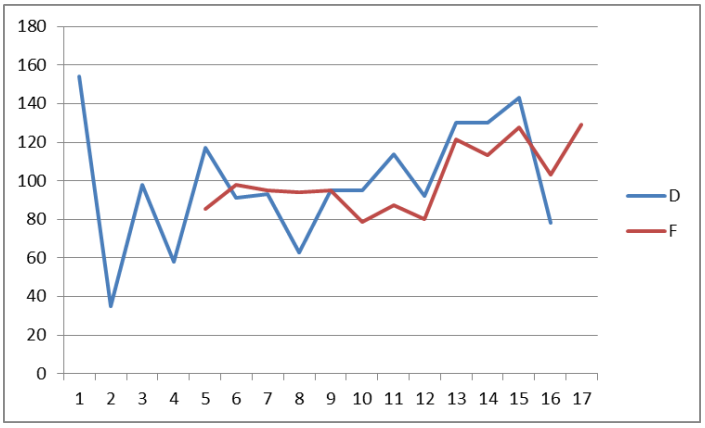


Dijagram 22 - Dijagram Holt metode. [1]

- **Trostruko eksponencijalno izglađivanje**

b) Multiplikativni model

Tablica 22 prikazuje izračun H.W. multiplikativne metode, za ovu metodu optimalne vrijednosti varijabli su: alpha=0,397211, beta=0, gama=0,821529. Ovaj dijagram pokazuje MAPE grešku od 17% što je u usporedbi s ostalim metodama najmanji postotak greške u izračunu, tj. predviđanju potražnje. Dijagram 23 prikazuje stvarnu potražnju i predviđanje potražnje dobiveno Holt Winters multiplikativnom metodom.



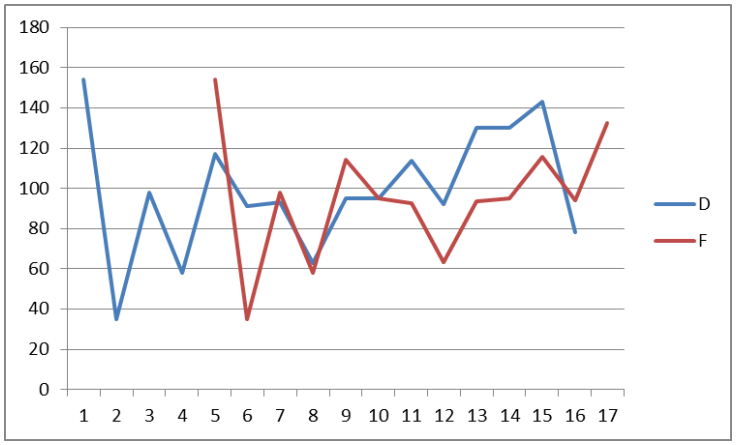
Dijagram 23 - Dijagram Holt Winters multiplikativne metode. [1]

Tablica 22 - Izračun Holt Winters multiplikativne metode. [1]

Level (*alpha*):	0,397211		Trend (*beta*):		0	Sezonalnost (*gama*):			0,821529
t	**D**	***Level***	***Trend***	***Season***	**F**	**e**	**e^2**	**|e|**	***MAPE***
1	**154**	**154,00**	**0,00**	**1,00**					
2	35	106,73	0,00	**1,00**					
3	98	103,26	0,00	**1,00**					
4	58	85,28	0,00	**1,00**					
5	117	**97,88**	0,00	1,16	85	-31,7	1005,9	31,7	37,19
6	91	95,15	0,00	0,96	98	6,9	47,4	6,9	7,03
7	93	94,30	0,00	0,99	95	2,1	4,6	2,1	2,26
8	63	81,86	0,00	0,81	94	31,3	979,4	31,3	33,19
9	95	81,86	0,00	1,16	95	0,0	0,0	0,0	0,00
10	95	88,48	0,00	1,05	79	-16,1	258,2	16,1	20,36
11	114	99,14	0,00	1,12	87	-26,5	703,0	26,5	30,31
12	92	104,83	0,00	0,87	80	-11,6	135,3	11,6	14,47
13	130	107,69	0,00	1,20	122	-8,3	69,6	8,3	6,86
14	130	113,90	0,00	1,13	114	-16,5	271,7	16,5	14,52
15	143	119,32	0,00	1,18	128	-15,3	234,0	15,3	11,98
16	78	107,72	0,00	0,75	103	25,3	639,5	25,3	24,48
17					**129**				
∑						-60,4	4348,6	191,7	
			***MAE*:**	16	***RMSE*:**	19	***MAPE*** (%):		17

c) Aditivni model

Tablica 23 prikazuje izračun H.W. aditivne metode, za ovu metodu optimalne vrijednosti varijabli su: alpha=0, beta=0, gama=1,071429. Alpha i beta varijable nisu aktivne, dok je gama prisutna s znatno velikom vrijednosšću. Ovaj dijagram pokazuje MAPE grešku od 33% što je u usporedbi s ostalim metodama dosta velik postotak greške u izračunu, tj. predviđanju potražnje, što ukazuje da se ovaj model slabo prilagođuje ovoj vrsti potražnje. Dijagram 24 prikazuje stvarnu potražnju i predviđanje potražnje dobiveno H.W. aditivnom metodom.



Dijagram 24 - Dijagram Holt Winters aditivne metode. [1]

Tablica 23 - Izračun Holt Winters aditivne metode. [1]

Level (*alpha*):		0	Trend (*beta*):		0	Sezonalnost (*gama*):			1,071429
Period	**D**	***Level***	***Trend***	***Season***	**F**	**e**	**e^2**	**|e|**	***MAPE***
1	**154**	**154,00**	**0,00**	**67,75**					
2	35	154,00	0,00	**-51,25**					
3	98	154,00	0,00	**11,75**					
4	58	**86,25**	0,00	**-28,25**					
5	117	86,25	0,00	28,11	154	37,0	1369,0	37,0	24,03
6	91	86,25	0,00	8,75	35	-56,0	3136,0	56,0	160,00
7	93	86,25	0,00	6,39	98	5,0	25,0	5,0	5,10
8	63	86,25	0,00	-22,89	58	-5,0	25,0	5,0	8,62
9	95	86,25	0,00	7,37	114	19,4	374,7	19,4	16,93
10	95	86,25	0,00	8,75	95	0,0	0,0	0,0	0,00
11	114	86,25	0,00	29,28	93	-21,4	456,1	21,4	23,05
12	92	86,25	0,00	7,80	63	-28,6	820,4	28,6	45,21
13	130	86,25	0,00	46,35	94	-36,4	1323,7	36,4	38,86
14	130	86,25	0,00	46,25	95	-35,0	1225,0	35,0	36,84
15	143	86,25	0,00	58,71	116	-27,5	754,8	27,5	23,78
16	78	86,25	0,00	-9,40	94	16,0	257,5	16,0	17,06
17					**133**				
∑						-132,5	9767,3	287,3	
			***MAE*:**	24	***RMSE*:**	29	***MAPE*** (%):		33

- **Usporedba rezultata metoda prognoza potražnje**

Usporedbom navedenih metoda za podatke potražnje koji su upotrijebljeni u svim izračunima, Holt Winterov multiplikativna metoda se je pokazala kao najviše točna metoda s najmanje greške s obzirom na ostale metode.

Tablica 24 - Usporedba grešaka metoda prognoze potražnje. [1]

Pomični prosjek (p=5)					
MAE:	20,09	RMSE:	24,78	MAPE (%):	20,38
Pomični prosjek (p=3)					
MAE:	25,03	RMSE:	30,34	MAPE (%):	26,77
Težinski prosjek (p=3)					
MAE:	20,65	RMSE:	24,63	MAPE (%):	20,76
Eksponencijalno izglađivanje (alfa=0,4705)					
MAE:	27,84	RMSE:	39,87	MAPE (%):	25,28
Eksponencijalno izglađivanje (alfa=0,2)					
MAE:	30,54	RMSE:	42,12	MAPE (%):	25,52
Holt					
MAE:	27,84	RMSE:	39,87	MAPE (%):	25,28
Winters multiplikativ					
MAE:	**15,97**	RMSE:	**19,04**	MAPE (%):	**16,89**
Winters aditiv					
MAE:	23,94	RMSE:	28,53	MAPE (%):	33,29

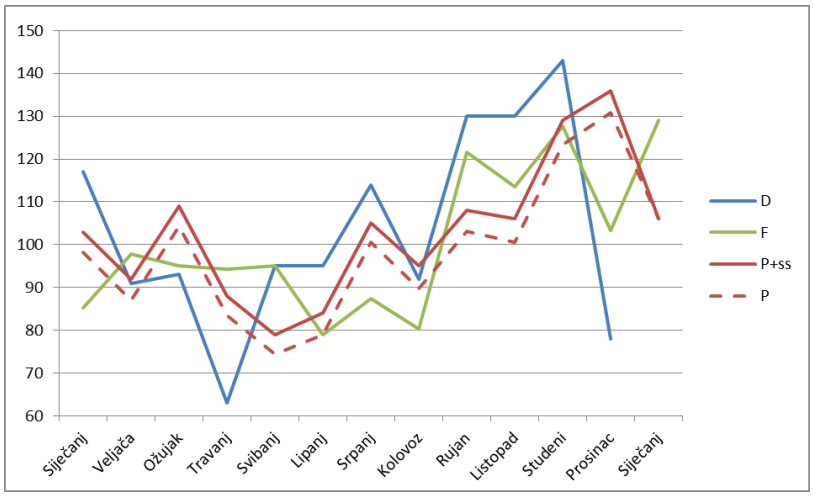
Kod analiza valja uzeti u obzir i oblik potražnje uzet za izračune koji nije uniformalan što pogoduje metodama prosjeka i eksponencijalnog izglađivanja. S obzirom da Holt Winter metoda ima tri varijable koje su vezane te karakteristike podataka s tom metodom se može postići najtočnija prognoza za ovakav set podataka.

- **Usporedba rezultata H.W. multiplikativne metode i P modela**

Tablica 25 uspoređuje greške dvaju navedenih metoda. Oba dvije daju slične no osebujno različite rezultate.

Tablica 25 - Usporedba grešaka H.W. multiplikativa i P modela od 2 mjeseca, [1]

H.W. multiplikativ	**MAE:**	16	**RMSE:**	19	**MAPE** (%):	17
P model, 2 perioda	**MAE:**	18	**RMSE:**	23	**MAPE** (%):	17



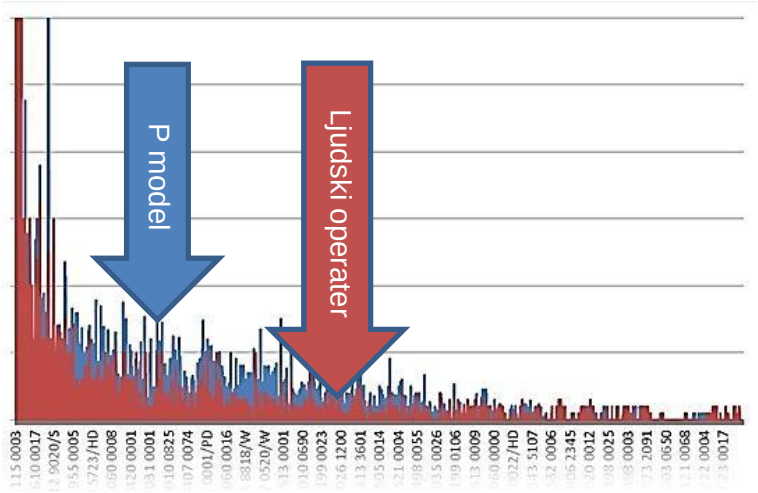
Dijagram 25 - Usporedba P modela, H.W. multiplikativa i stvarne potražnje. [1]

Analizom metoda prognoze potražnje pokazane su različitosti, tj. karakteristike navedenih metoda. Temeljem tih karakteristika odabire se metoda koja je najpovoljnija za vršenje prognoze potražnje s obzirom na vrstu potražnje, količinu podataka itd.

6.4 USPOREDBA P MODELA I LJUDSKOG OPERATERA

Analizom P modela (6.2) dobiven je optimalan oblik modela s najmanjom greškom zadovoljavanja potražnje. Sljedeća bitna analiza je usporedba P modela s ljudskim operaterom.

Sljedeći dijagram prikazuje količine narudžbe naručene robe od strane ljudskog operatera (osobe s dugogodišnjim iskustvom kontrole razine zaliha) i od strane izračuna optimalnih zaliha P modelom za jednu narudžbu. Narudžba odrađena ljudskim operaterom je izvršena bez uporabe modela kontrole zaliha ili modela predviđanja potražnje.



Dijagram 26 - Usporedba P modela i narudžbe ljudskog operatera. [1]

Primjetno je da između dvije narudžbe nema prisutnih neregularnih odstupanja, tj. ponašanje podataka narudžbe izvedene formulom P modela dijeli simetriju narudžbe napravljene od strane osobe s dugogodišnjim iskustvom.

Razlike postoje, vidljivo je po dijagramu da je narudžba izrađena P modelom izračunala da su generalno potrebne nešto veće zalihe no od narudžbe napravljene od strane ljudskog operatera (utjecaj politike većih sigurnosnih zaliha). P model bazira izračun na periodima od dva tjedna.

Sljedeća tablica prikazuje sumu naručene robe. Prema P modelu je naručeno je 1.480 komada više robe od ljudskog operatera. Tih 1.500 komada razlike predstavlja izračun optimalnog nivoa zaliha narudžbe u smislu osiguravanja zadovoljenja potražnje dobivenim temeljem prodajnih podataka.

6399 kom	4919 kom
P model	**Ljudski operater**

Tablica 26 - Suma količina narudžbe između P modela i ljudskog operatera. [1]

Tablica 27 pokazuje kako se danjom analizom može vidjeti da je postojalo prosječno 33% odstupanje narudžbe P modela od narudžbe ljudskog operatera u smislu naručenih količina. Tih 33% predstavlja odstupanje naručenih količina P modelom od narudžbe koju je ljudski operater napravio, odstupanje je i iznad i ispod količina određenih od strane ljudskog operatera kao optimalna narudžba. Daljnjom doradom razlika uviđa se da je u samo 14% artikala putem P modela naručeno manje zaliha za cijelu narudžbu po svakoj stavci no što je ljudski operater odredio kao optimalnu razinu zaliha.

Tablica 27 - Postotak razlike P modela od narudžbe operatera. [1]

33%	14%
Razlika naspram narudžbe operatera	**Manje naručeno nego operater**

- **Stanje na dan narudžbe**

Narudžba po P modelu bi povećala zalihe lagera na ukupno 33.350 komada proizvoda, dok je od ljudskog operatera narudžba povećala lager na manju količinu od 31.862 komada. Predloženo povećanje zaliha lagera je za 1.488 komada veće (4,46%) u odnosu na narudžbu operatera.

Tablica 28 - Lager prije prodaje. [1]

	P model	Operater
Lager prije prodaje	33.350 kom	31.862 kom
	4,46% razlika	

- **Stanje nakon isteka perioda prodaje**

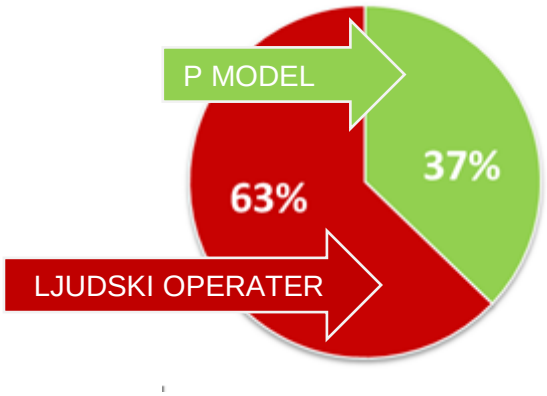
Od vremena slanja narudžbe do vremena primitka sljedećeg uvoza je prošlo 13 dana ukupno tj. 9 radnih dana (+ neplanirano kašnjenje isporuke sljedećeg uvoza). Prvobitno planirani period je 10 radnih dana, tj. dva puna tjedna koja mora pokriti narudžba. Ranija obrada sljedeće narudžbe i ranija isporuka robe ukazuje na to da narudžba od ljudskog operatera nije potpuno zadovoljila potražnju za predviđeni period. Nakon isteka perioda prodaje razlika između predloženog stanja zaliha P modelom i narudžbe operatera je 4,82%. tj. predloženo stanje lagera u odnosu na narudžbu operatera bi nakon prodaje bilo veće za 4,82%.

Tablica 29 - Lager nakon prodaje. [1]

	P model	Operater
Lager nakon prodaje	30.862 kom	29.374 kom
	4,82% razlika	

6.4.1 PREGLED NEZADOVOLJENE POTRAŽNJE

Usporedbom lagera koji bi bio ostvaren korištenjem P modela za narudžbe i aktualno stanje lagera dobiveno povećanjem narudžbe ljudskog operatera zamjetna je znatna razlika između proizvoda koji su se rasprodali i kojima je prodaja prekinuta radi rasprodaje zaliha, tj. manjka zaliha. Najvažniji podatak ove analize je taj kod koliko proizvoda su zalihe rasprodane, gdje naručene količine nisu pokrile potražnju za predviđeni period jer im je stanje palo na nulu ili nisu bili dostupni a pokazala se za njima potražnja prije sljedećeg uvoza.



Dijagram 27 – Postoci nedostupnih proizvoda nakon isteka perioda prodaje. [1]

Aktualno stanje lagera povećanog narudžbom operatera sadrži 235 vrsti proizvoda kojima su zalihe rasprodane ili nenaručene čime im je potražnja prekinuta (nije zadovoljena) zbog čega je došlo do gubitka potencijalne prodaje. Predloženo stanje lagera povećano narudžbom dobivenom P modelom sadrži 139 proizvoda kojima su zalihe nedostupne. U odnosu na nezadovoljenu potražnju narudžbe operatera, P model je imao bolje predviđanje potražnje, gdje je gubitak mogao biti umanjen za 41%, tj. 69% u odnosu na P model.

Tablica 30 - Količine nedostupnih zaliha nakon isteka perioda prodaje. [1]

	P model	Operater
Nedostupni proizvodi	139	235
Negativne razlike	1	0

Drugi aspekt koji je bitan radi međusobnog uspoređivanja je koliko je narudžba operatera prodala više proizvoda u usporedbi s P modelom narudžbe. Postojeća razlike je za jedan proizvod i iznosi jedan komad ekstra proizvoda koji ne bi bio prodan uporabom narudžbe dobivene P modelom (originalno dobivena P modelom optimalna narudžba je sadržavala 14% manje proizvoda naručena nego narudžba operatera). Taj podatak ukazuje također da je aktualna prodaja bila zadovoljena minimalno koliko je zadovoljena narudžbom operatera, pa i više uzevši u obzir da je bilo manje proizvoda kojima je stanje bilo nula prije kraja prodajnog perioda. Podatak da je operater naručio 14% proizvoda više nego je P model a da je prodan samo jedan proizvod više nego što je P model predvidio preporučio ukazuje na krivu preraspodjelu predviđanja dijela potražnje.

6.4.2 PREGLED RASPRODANIH I NENARUČENIH PROIZVODA

Pregledom vrsti rasprodanih proizvoda prema dolje priloženoj tablici vidi se da je kod narudžbe operatera udarnih rasprodanih proizvoda bilo 22 vrste dok kod P modela 6 vrsti. Nadalje, srednje udarni artikli kod narudžbe operatera sadrži 61 vrstu proizvoda dok P model 17 koja su bila rasprodana, razlika je ovdje poveća. Na kraju sporo prodajni proizvodi su kod narudžbe operatera sadržavali 151 vrstu koja je bila rasprodana, dok kod P modela 123 vrste.

Rezultati pokazuju znatno učinkovitije predviđanje potražnje od strane P modela, s time da je najveća razlika kod srednje brzo prodajnih artikala.

Tablica 31 - Usporedba ABC kategorizacije na nedostupne proizvode. [1]

ABC P model	
A	6
B	17
C	123
	146

ABC operater	
A	22
B	61
C	151
	234

Ne naručena roba se nadalje dijeli u dvije kategorije:

1) **Ne obrađene šifre s stanjem nula**

Usporedbom narudžbe P modela i narudžbe operatera 114 artikala nije naručeno a prodaja ima je regularna (stanje lagera im bilo nula). P model daje prijedlog količina narudžbe za navedene šifre (498 komada ukupno). 17 artikala su udarni artikli koji uopće nisu naručeni. Veći dio ovih šifri su artikli s sporijom obrtajem kojima prodaja nije konstantna iz tjedna u tjedan, no opet je prisutna i regularna no s dužim intervalima između prodaje.

2) **Premala količina narudžbe**

21 šifra artikla nije bila naručena u narudžbi operatera a u cijelosti se rasprodala tijekom prodajnog perioda. Zalihe ovih šifri su trebale biti podebljane. P model je predvidio kod ovih artikala da su potrebne veće količine narudžbe prema prosječnoj prodaji i prosječnom odstupanju od prosječne prodaje. Ukupna količina artikala je 59 komada.

Uporabom prodajnih podataka i usporedbom dvije vrste narudžbi, pokazalo se je da je P model bio vrlo sličan no marginalno točniji kod predviđanja potražnje no operater. Općenito obje narudžbe su slične, no P model bi umanjio pad prodaje kod rasprodanih artikala za 41%, što ukazuje i veća količina narudžbe koju je P model predloži s obzirom na prodajne podatke.

7. ZAKLJUČAK

Pregledom sustava veleprodajne tvrtka uviđa se kompleksnost popratnog logističkog sustava. Premda je u diplomskom radu razrađena manja veleprodajna tvrtka jasna je prisutna širina logistike i raznih analiza koje se potrebna za efektivno i efikasno funkcioniranje takve tvrtke.

Definiranje, tj. strukturiranje, skladišnih operacija omogućuje kontrolu nad tokovima zaliha kojima se teži konstanta optimizacija da bi se smanjio ukupni trošak poslovanja tj. ostvarila što veća dobit. S obzirom na navedene elemente koje dotiču veleprodajnu tvrtku bitno je obaviti analizu postojećih procesa jer u suprotnom procesi mogu stvarati nepotrebne troškove.

Kako su skladišni objekti dugoročne investicije koje je skupo adaptirati, a zalihe i priroda posla s zalihama teško lokacijski promjenjiva, bez velikih gubitaka i troškova, bitno je poznavati raspoložive kapacitete objekta i mogućnosti suprastrukturnih skladišnih elemenata da bi se maksimalni ali i efektivno uporabio raspoloživi prostor. Projektiranje suprastrukture se treba vršiti s obzirom na prisutne skladišne operacije i infrastrukturu objekta. Moguća najviše optimalna rješenja ne moraju nužno biti i najbolja kako ona sa sobom nose i znatan trošak, no omogućuju stvaranje i definiranje cilja kojemu se treba težiti.

Za manju veleprodajnu tvrtku organizacija uskladištenja zaliha nudi prednosti koje su bitne kako je uporaba WMS modula neisplativa za manje tvrtke. Organizacija pruža podršku na način da se može lakše i cjelovitije upravljati sa zalihama, te da se može kroz logiku organizacije po potrebi napraviti i povratna logika da bi se lakše otkrile eventualne greške koje su skupe za pronalazak i ispravljanje radi velike količine zaliha.

S obzirom na prirodu naručivanja zaliha kod veleprodajne tvrtke, jedina prikladna metoda optimizacije zaliha koje se naručuju je P model koji okrupnjuje narudžbe prema proizvoljnim vremenima naručivanja, poželjno je kako su pokazale analize da se koristi manji period kod izračuna. Dodatnu podrška naručivanju omogućuje i multiplikativna Holt Winters metoda koja se pokazala kao najtočnija metoda prognoze potražnje.

Uporabom obrađenih logističkih sredstava ukazuje se na postojeća ograničenja te definira moguća rješenja koja si bitna radi daljnjeg napredovanja koje je jedino moguće ostvariti primjenom efikasnih i efektivnih odluka poduprtim logistikom. Uporabom navedenih metoda i alata očekuje se smanjenje troškova rada i povećanje zadovoljenja potražnje.

8. POPIS KRATICA

ERP (enterprise resource planning / planiranje resursa poslovnog sustava)
WMS (warehouse management system / sistem upravljanja skladištem)
RFID (radio frequency identification)
IT (information techologies / informacijske tehnologije)
EDI (electronic data interchange / elektronička razmjena podataka)
FILO (first-in, last-out / prvi unutra, zadnji van)
FIFO (first-in, first-out / prvi unutra, prvi van)
UPC (Universal Product Code)
EAN (European Article Number)
MAE (mean absolute error / srednje apsolutno odstupanje)
RMSE (root mean squared error / korijen srednje kvadratne pogreške)
MAPE (mean absolute percent error / prosječna postotna apsolutna pogreška)
D (demand / potražnja)
F (forecast / predviđanje)
e (error/ greška)

9. IZVORI

[1] Saša Butina, podaci prikupljeni tijekom rada u veleprodajnoj tvrtci Kineo tehne d.o.o.; 2013-2015.
[2] William Stevenson, Operations Management, 2011, ISBN-13: 978-0073525259
[3] prof. dr. sc. Kristijan Rogić, Autorizirana predavanja, kolegij: „Skladištenje i unutrašnji transport“, Fakultet prometnih znanosti; 2008.
[4] John J. BartholdI III., Constructing a “heat map” of the warehouse [Internet], 6.7.2015 u 24:00, dostupno na: http://www2.isye.gatech.edu/~jjb/wh/apps/bev/bev.html
[5] Prajakta S. Kalekar, Time series Forecasting using Holt-Winters Exponential Smoothing, Kanwal Rekhi School of Information Technology; 2004.
[6] SAP Internet stranica, ERP rješenja automotivne industrije [Internet], 6.7.2015 u 24:00, dostupno na: http://go.sap.com/solution/industry/automotive.html
[7] Microsoft Dynamics Internet stranica, ERP rješenja maloprodaje [Internet], 06.7.2015 u 24:00, dostupno na: https://www.microsoft.com/en-us/dynamics/retail.aspx
[8] Visco-Eagle Internet stranica, katalog od konvejera do regala [Internet], 06.7.2015 u 24:00, dostupno na: http://www.cisco-eagle.com/catalog/default.aspx
[9] prof. dr. sc. Mario Šafran, Autorizirana predavanja, kolegij: „Upravljanje zalihama“, Fakultet prometnih znanosti; 2012.
[10] prof. dr. sc. Kristijan Rogić, Autorizirana predavanja, kolegij: „Distribucijska logistika I“ i „Distribucijska logistika II“, Fakultet prometnih znanosti; 2014/2015.
[11] Robert Jacobs, Richard Chase, Operations and Supply Chain Management; 2013, ISBN-13: 978-0078024023.
[12] Kenneth B. Ackerman, Practical Handbook of Warehousing, Chapman & Hall Materials Management / Logistics Series; 1997, ISBN-13: 978-0412125119.
[13] Dave Piasecki, Warehouse Management Systems (WMS). [Internet], dostupno na: http://www.inventoryops.com/warehouse_management_systems.htm
[14] Saša Butina, podaci prikupljeni tijekom rada u veleprodajnoj i maloprodajnoj tvrtci Intercars d.o.o., 2012.
[15] Measurement Equipment Corporation, Different Types of Barcodes [Internet], dostupno na: http://www.mecsw.com/specs/speclist.html

10. POPIS SLIKA

Slika 1 - Dijagram toka koraka odabira skladišta. [3] 4
Slika 2 - Prikaz skladišta s osnovnim skladišnim operacijama. [1] 6
Slika 3 - Procesi skladišnog sustava s osnovnim operacijama i aktivnostima. [1] 7
Slika 4 - Operacije prijema, cross docking-a, komisioniranja i otpreme. [1] 8
Slika 5 - Prikaz internet kataloga s cijenama i asortimanom. [1] 10
Slika 6 - Dijagram toka obrade reklamacije unutar opskrbnog lanca. [1] 16
Slika 7 - Različite izvedbe regala lake izvedbe. [1] 19
Slika 8 - Paletni regali dubine palete. [1] 20
Slika 9 - Ulazni paletni regali. [1] 21
Slika 10 - Prikaz provoznih paletnih regala. [1] 22
Slika 11 - Prikaz gravitacijskog paletnog regala. [1] 23
Slika 12 - Prikaz teleskopskog paletnog regala. [1] 24
Slika 13 – Opći prikaz utjecaja karakteristika robe kod pozicioniranja na regale. [1] 25
Slika 14 - Prikaz izvedbe police i regala. [1] 27
Slika 15 – Prikaz organiziranih i neorganiziranih zaliha na regalima. [1] 27
Slika 16 - Označavanje lokacije regala barkodom. [1] 31
Slika 17 - Skladišne zone. [1] 32
Slika 18 – *Cross-docking*. [1] 32
Slika 19 - Prikaz skladištenja zaliha prema robnim grupama. [1] 33
Slika 20 - Prikaz međusobnih omjera robnih grupa. [1] 33
Slika 21 - Dijagram ABC kategorizacije. [1] 34
Slika 22 - ABC kategorizacija prema regalima različitih veličina. [1] 34
Slika 23 - ABC kategorizacija prema zoni otpreme. [1] 35
Slika 24 - ABC kategorizacija prema glavnim prolazima. [1] 35
Slika 25 - Prikaz toplinske mape po redovima skladišnih regala. [1,4] 36
Slika 26 - 3D prikaz toplinske mape skladišnih regala. [1] 36
Slika 27 - Oblici potražnje. [1, 2] 45
Slika 28 - Tlocrt skladišnog objekta s suprastrukturom uzetog primjera. [1] 55
Slika 29 - Karakteristike jedne konzole regala. [1] 55
Slika 30 - Potencijalni prostor za skladištenje. [1] 56
Slika 31 - Prikaz predloženog rješenja etažiranog skladišta. [1] 57
Slika 32 - Izmjene prizemne regalne suprastrukture. [1] 58
Slika 33 - Izmjene etažne regalne suprastrukture. [1] 59

11. POPIS DIJAGRAMA

Dijagram 1 – Neki od modula ERP sustava. [1,6,7] 2
Dijagram 2 - Koraci prisutni kod *cross-docking*-a. [1] 9
Dijagram 3 - Proces obrade narudžbe. [1] 11
Dijagram 4 - Dijagram toka procesa izlaza robe iz skladišta. [1] 12
Dijagram 5 - Prosječna količina skladišnih operacija komisioniranja u danu. [1] 13
Dijagram 6 - Izlazni promet robe u komadima unutar godine dana. [1] 13
Dijagram 7 - Opskrbni i povratni lanac. [1] 15
Dijagram 8 - Pravilo izrade lokacija. [1].....28
Dijagram 9 - Primjer komisioniranja pomoću lokacija putem WMS sustava. [1] 29
Dijagram 10 - Primjer komisioniranja pomoću lokacija bez WMS sustava. [1] 29
Dijagram 11 - Dijagram toka P i Q modela. [1].....39
Dijagram 12 - P model. [1,3].....41
Dijagram 13 - Prikaz multiplikativa i aditiva. [1].....51
Dijagram 14 - Dijagram izračuna optimalnih zaliha P modelom za period od 12 mjeseci. [1] 61
Dijagram 15 - Dijagram izračuna optimalnih zaliha P modelom za period od 4 mjeseca. [1] 62
Dijagram 16 - Dijagram izračuna optimalnih zaliha P modelom za period od 2 mjeseca. [1] 64
Dijagram 17 - Dijagram potražnje i optimalnih zaliha za period od 12, 4 i 2 mjeseca. [1] 65
Dijagram 18 - Dijagram potražnje za primjere izračuna prognoza. [1].....66
Dijagram 19 - Dijagram pomičnih prosjeka za 3 i 5 perioda. [1] 68
Dijagram 20 - Dijagram težinskog prosjeka za 3 perioda. [1] 69
Dijagram 21 - Dijagram eksponencijalnog izglađivanja. [1] 71
Dijagram 22 - Dijagram Holt metode. [1].....72
Dijagram 23 - Dijagram Holt Winters multiplikativne metode. [1].....73
Dijagram 24 - Dijagram Holt Winters aditivne metode. [1].....74
Dijagram 25 - Usporedba P modela, H.W. multiplikativa i stvarne potražnje. [1].....76
Dijagram 26 - Usporedba P modela i narudžbe ljudskog operatera. [1] 77
Dijagram 27 – Postoci nedostupnih proizvoda nakon isteka perioda prodaje. [1].....79

12. POPIS TABLICA

Tablica 1 - Izgledi različitih tipova barkodova. [1,15] 31
Tablica 2 - Usporedba karakteristika P i Q modela. [1] 39
Tablica 3 - Usporedba vremena provjere razine zaliha kod Q i P modela. [1] 40
Tablica 4 - Izračun naivne metode. [2] 47
Tablica 5 - Tablica odabira prognoze potražnje. [2] 53
Tablica 6 - Izračun ukupne kvadrature i kubika skladišne suprastrukture primjera. [1] 56
Tablica 7 – Odnosi prisutnih zona u skladištu. [1] 56
Tablica 8 - Izračun raspoloživih kubika ne iskorištenog skladišnog prostora. [1] 57
Tablica 9 - Izračun raspoloživih kubika prizemnog dijela etažne suprastrukture. [1].....58
Tablica 10 - Izračun raspoloživih kubika etažnog dijela suprastrukture. [1] 59
Tablica 11 - Primjer izračuna optimalnih zaliha P modelom za period od 12 mjeseci. [1].....60
Tablica 12 - Izračun pogreške P modela perioda 12 mjeseci i stvarne potražnje. [1].....61
Tablica 13 - Primjer izračuna optimalnih zaliha P modelom za period od 4 mjeseca. [1].....62
Tablica 14 - Izračun pogreške P modela perioda 4 mjeseca i stvarne potražnje. [1] 63
Tablica 15 - Primjer izračuna optimalnih zaliha P modelom za period od 2 mjeseca. [1].....63
Tablica 16 - Izračun pogreške P modela perioda 2 mjeseca i stvarne potražnje. [1] 64
Tablica 17 - Podaci potražnje za izračune. [1] 66
Tablica 18 - Izračun pomičnog prosjeka za 3 i 5 perioda. [1].....67
Tablica 19 - Izračun težinskog prosjeka. [1] 69
Tablica 20 - Izračun eksponencijalnog izglađivanja. [1].....70
Tablica 21 - Izračun Holt metode. [1] 72
Tablica 22 - Izračun Holt Winters multiplikativne metode. [1] 73
Tablica 23 - Izračun Holt Winters aditivne metode. [1] 74
Tablica 24 - Usporedba grešaka metoda prognoza potražnji. [1] 75
Tablica 25 - Usporedba grešaka H.W. multiplikativa i P modela od 2 mjeseca, [1] 76
Tablica 26 - Suma količina narudžbe između P modela i ljudskog operatera. [1] 77
Tablica 27 - Postotak razlike P modela od narudžbe operatera. [1] 78
Tablica 28 - Lager prije prodaje. [1] 78
Tablica 29 - Lager nakon prodaje. [1] 78
Tablica 30 - Količine nedostupnih zaliha nakon isteka perioda prodaje. [1].....79
Tablica 31 - Usporedba ABC kategorizacije na nedostupne proizvode. [1] 80

METAPODACI

Naslov rada: _____

Autor: _____

Mentor: _____

Naslov na drugom jeziku (engleski):

Analysis of wholesale logistic systems

Povjerenstvo za obranu:

- _____ predsjednik
- _____ mentor
- _____ član
- _____ zamjena

Ustanova koja je dodijelila akademski stupanj: Fakultet prometnih znanosti Sveučilišta u Zagrebu

Zavod: _____

Vrsta studija: Diplomski

Naziv studijskog programa: Logistika

Stupanj:

_____

Akademski naziv:

_____

Datum obrane završnog rada:_____

Sveučilište u Zagrebu
Fakultet prometnih znanosti
Vukelićeva 4, 10000 Zagreb

IZJAVA O AKADEMSKOJ ČESTITOSTI I SUGLASNOST

Izjavljujem i svojim potpisom potvrđujem da je diplomski rad sključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu, a što pokazuju korištene bilješke i bibliografija. Izjavljujem da nijedan dio rada nije napisan na nedozvoljen način, odnosno da je prepisan iz necitiranog rada, te da nijedan dio rada ne krši bilo čija autorska prava. Izjavljujem, također, da 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 „Analiza logističkog sustava veleprodajne tvrtke“, na internetskim stranicama i repozitoriju Fakulteta prometnih znanosti, Digitalnom akademskom repozitoriju (DAR) pri Nacionalnoj i sveučilišnoj knjižnici u Zagrebu.

Student:

U Zagrebu,_____ _____

(potpis)