Prognoziranje nabave u poduzeću Hilding Anders d.o.o.

Grabant, Tatjana

Master's thesis / Diplomski rad

2018

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University North / Sveučilište Sjever**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:122:886844

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-24**

Repository / Repozitorij:

University North Digital Repository

SVEUČILIŠTE SJEVER

SVEUČILIŠNI CENTAR VARAŽDIN

DIPLOMSKI RAD br.

PROGNOZIRANJE NABAVE U PODUZEĆU HILDING ANDERS D.O.O.

Tatjana Grabant, 0340/336 D

Varaždin, ožujak 2018.

SVEUČILIŠTE SJEVER

SVEUČILIŠNI CENTAR VARAŽDIN

Poslovna ekonomija

DIPLOMSKI RAD br.

PROGNOZIRANJE NABAVE U PODUZEĆU HILDING ANDERS D.O.O

Student:

Tatjana Grabant, 0340/336 D

Mentor:

doc. dr. sc. Damira Đukec

Varaždin, ožujak 2018.

Sveučilište Sjever
Sveučilišni centar Varaždin
104. brigade 3, HR-42000 Varaždin

Prijava diplomskog rada

studenata IV. semestra diplomskog studija
Poslovna ekonomija

IME I PREZIME STUDENTA: Tatjana Grabant | MATIČNI BROJ: 0340/336 D

NASLOV RADA: Prognoziranje nabave u poduzeću Hilding Anders d.o.o.

NASLOV RADA NA ENGL. JEZIKU: Forecasting procurement in Hilding Anders d.o.o.

KOLEGIJ: Kvantitativne metode poslovnog odlučivanja

MENTOR: doc. dr. sc. Damira Đukec

ČLANOVI POVJERENSTVA:
1. izv. prof. dr. sc. Ante Rončević, predsjednik
2. doc. dr. sc. DinkoPrimorac, član
3. doc. dr. sc. Damira Đukec, mentor
4. izv. prof. dr. sc. Anica Hunjet

Zadatak diplomskog rada

BROJ: 220/PE/2108

OPIS:

Cilj rada je pojasniti način prognoziranja nabave materijala za proizvodnju u poduzeću Hilding Anders d.o.o. Prognoziranje se može definirati kao predviđanje budućih događaja koje se zasniva na objektivnim i provjerenim činjenicama uz pomoć provjerenih znanstvenih metoda. Metoda trenda, korelacije i regresije će biti detaljno teorijski objašnjene te će se metodom linearnog trenda prognozirati potrebe materijala za nekoliko tjedana na temelju podataka dobivenih u poduzeću Hilding Anders d.o.o. Jedna od karika koja postaje sve važnija u ostvarenju postavljenih ciljeva poduzeća je svakako nabava, a time i kvalitetno prognoziranje potreba i upravljanje zalihama. Dio rada posvećen je povijesti i razvoju poduzeća Hilding Anders d.o.o. iz Preloga te načinu planiranja nabave. Hilding Anders je tržišni lider na regionalnom tržištu madraca te snažan brand prepoznat od strane krajnjih korisnika kao sinonim za udobnost, kvalitetu i zdravlje. Podaci dobiveni u poduzeću usporedit će se s rezultatima dobivenim primjenom metode linearnog trenda i napravit će se komparativna analiza prognoziranja nabave.

U VARAŽDINU, DANA 13.03.2018. | POTPIS MENTORA

SVEUČILIŠTE SJEVER

DIR 01 PE

Sažetak

Cilj rada je pojasniti način prognoziranja nabave materijala za proizvodnju u poduzeću Hilding Anders d.o.o. Prognoziranje se može definirati kao predviđanje budućih događaja koje se zasniva na objektivnim i provjerenim činjenicama uz pomoć provjerenih znanstvenih metoda. Metode trenda, korelacije i regresije će biti detaljno teorijski objašnjene te će se metodom linearnog trenda prognozirati potrebe materijala za nekoliko tjedana na temelju podataka dobivenih u poduzeću Hilding Anders d.o.o. Dio rada posvećen je povijesti i razvoju firme Hilding Anders d.o.o iz Preloga te načinu planiranja nabave. Hilding Anders je tržišni lider na regionalnom tržištu madraca te snažan brand prepoznat od strane krajnjih korisnika kao sinonim za udobnost, kvalitetu i zdravlje. Hilding Anders u svom proizvodnom programu ima sve proizvode vezane za kvalitetno spavanje. Podaci dobiveni u poduzeću usporedit će se s rezultatima dobivenim primjenom metode linearnog trenda i napravit će se komparativna analiza prognoziranja nabave.

Ključne riječi: prognoziranje, nabava, proizvodi, materijali za proizvodnju, linearni trend, Hilding Anders d.o.o.

Abstract

The aim of the thesis is to explain the way of forecasting the procurement of production materials in Hilding Anders Ltd. Forecasting can be defined as predicting the future events based on objective and verified facts with the help of proven scientific methods. The trend, correlation and regression methods will be explained in detail in the theoretical manner and the linear trend method will forecast the material needs for several weeks based on the data obtained at Hilding Anders Ltd. One part is devoted to the history and development of Hilding Anders Ltd. from Prelog and the way of procurement planning. Hilding Anders is the market leader in the regional mattress market and a strong brand recognized by end-users as a synonym for comfort, quality and health. Hilding Anders has in its production program all the products associated with quality sleep The data obtained in the company will be compared with the results

obtained using the method of linear trend and a comparative analysis of the forecast of procurement will be made.

Key words: forecasting, procurement, products, production materials, linear trend, Hilding Anders d.o.o.

SADRŽAJ

1. Uvod 4

2. Prognoziranje u ekonomiji 6

2.1. Važnost i metode prognoziranja u ekonomiji 6

2.2. Trend, korelacija i regresija 12

3. Pojam i svrha nabave 19

3.1. Nabava u užem smislu 19

3.2. Nabava u širem smislu 21

3.3. Zadaci nabave 22

3.4. Ciljevi nabave 23

3.5. Značenje nabave 24

3.6. Svrha nabave 25

3.7. Strategije nabave 25

3.8. Operativno planiranje nabave 27

4. Poduzeće Hilding Anders d.o.o. 31

4.1. Nabava u Hilding Andersu d.o.o. 37

4.2. Prognoziranje nabave u HA 41

5. Trend analiza nabave u Hilding Andersu 47

5.1. Prognoza potreba materijala za proizvodnju madraca modelom linearnog trenda 47

5.2. Komparativna analiza prognoziranja nabave 52

6. Zaključak 54

7. Literatura 57

POPIS TABLICA 58

POPIS SLIKA 58

1. Uvod

Cilj ovog diplomskog rada je pojasniti način prognoziranja nabave materijala za proizvodnju u poduzeću Hilding Anders d.o.o. te obraditi metode linearnog trenda na konkretnim primjerima. U sklopu ovoga diplomskog rada metode trenda, korelacije i regresije će biti detaljno teorijski objašnjene te će se metodom linearnog trenda prognozirati potrebe materijala za nekoliko tjedana na temelju podataka dobivenih u poduzeću Hilding Anders d.o.o. Podaci dobiveni u poduzeću usporedit će se s rezultatima dobivenim primjenom metode linearnog trenda i napravit će se komparativna analiza prognoziranja nabave.

Rad je podijeljen u šest sadržajnih cjelina. Nakon uvodnog dijela definiran je pojam prognoziranja i opisane su metode prognoziranja u ekonomiji. Jedna od osnovnih karakteristika poslovnog okruženja današnjice su brze i brojne promjene među kojima je i velika količina podataka s kojima se svakodnevno susrećemo. Ako su podaci prikupljeni planski, smatraju se statističkim te je njihovo pretvaranje u informacije moguće upotrebom statističkih metoda. Statističke metode se upotrebljavaju u svim sferama poslovanja: razvoju, proizvodnji, marketingu, financijama, računovodstvu i reviziji i dr. Jedna od statističkih metoda je i prognoziranje. Prognoziranje se može definirati kao predviđanje budućih događaja koje se zasniva na objektivnim i provjerenim činjenicama uz pomoć provjerenih znanstvenih metoda. U području poslovanja i ekonomije statističke su metode temeljne analitičke metode. Analitičkim postupcima uspoređuju se dostupni podaci s podacima prethodnih razdoblja, očekivanim rezultatima ili podacima iz iste gospodarske djelatnosti. U analitičke postupke se ubrajaju i statističke metode: trend, korelacija i regresija. Navedene metode se primjenjuju u mnogim stručnim i znanstvenim područjima te predstavljaju pojednostavljenu sliku stvarnih pojava. U praksi se koriste za utvrđivanje povezanosti između pojava te za predviđanje istih u budućnosti.

U turbulentnom okruženju, kakvo je danas, skoro pa svakodnevno ljudi se bave planiranjem. Planiraju svoje dnevne obaveze, planiraju aktivnosti ukućana, planira se potrošnja mjesečnog budžeta i sl. Planiranje u poduzećima također je jedna od važnijih poslovnih aktivnosti. Planiranje je proces koji utvrđuje viziju, misiju i ciljeve poduzeća te daje odgovore na pitanje gdje se poduzeće nalazi, gdje želi biti u budućem periodu

i kako tamo stići. Stoga je kvalitetno planiranje itekako važno za postizanje ciljeva i ostvarivanje definiranih strategija. Da bi poduzeće ostvarilo definiranu strategiju u poslovanju, nužno je da svaki odjel i proces bude u skladu sa zadanim ciljevima. Jedna od karika koja postaje sve važnija u ostvarivanju postavljenih ciljeva je svakako i nabava, a time i kvalitetno prognoziranje potreba i upravljanje zalihama. To nije ni lak ni jednostavan posao. Iziskuje izuzetno puno angažmana, usklađivanja, analiza, razmjenu informacija i podataka. Danas je nabava sve manje funkcija s taktičkim zadacima u svezi s izvršenjem zahtjeva za nabavu uz niske nabave cijene. Sve više postaje strateška funkcija i odluke se temelje na politici stvaranja vrijednosti te se teži snižavanju ukupnih troškova u lancu opskrbe.

Dio rada posvećen je povijesti i razvoju poduzeća Hilding Anders d.o.o. iz Preloga te načinu planiranja nabave. Hilding Anders je tržišni lider na regionalnom tržištu madraca te snažan brand prepoznat od strane krajnjih korisnika kao sinonim za udobnost, kvalitetu i zdravlje. Hilding Anders u svom proizvodnom programu ima sve proizvode vezane uz kvalitetno spavanje: madrace, jastuke, poplune, elastične podloge, različite vrste drvenih i tapeciranih kreveta te namještaj za spavaće i dječje sobe.

Posljednja stavka rada predstavlja trend analiza nabave u kojem se obrađuje trend analiza potrošnje nekoliko važnih materijala. Prikazom rezultata istraživanja, ciljevima i metodama istraživanja, podacima korištenim u istraživanju, u nastavku rada dat je primjer planiranja potreba nekoliko materijala prema sustavu firme, zatim se izračunava potreba primjenom linearnog trenda. Komparativnom analizom uspoređuju se podaci sa stvarnom potrošnjom kroz nekoliko tjedana.

Rad završava zaključkom u kojem su sažeto navedeni rezultati empirijskog istraživanja te zaključci dobiveni na temelju cijelog rada.

2. Prognoziranje u ekonomiji

Ovo poglavlje sastoji se od dva potpoglavlja. U prvom je objašnjena važnost i metode prognoziranja u ekonomiji, a u drugom su detaljno objašnjeni trend, korelacija i regresija.

2.1. Važnost i metode prognoziranja u ekonomiji

U području poslovanja i ekonomije temeljne analitičke metode jesu statističke metode. Uloga statistike kao znanstvene metode koju je moguće primijeniti u svim područjima ljudskog djelovanja je izrazito velika. Statistički podaci o gospodarskim kretanjima, statistički pokazatelji i modeli omogućuju praćenje gospodarskih kretanja, provođenje gospodarske politike, poslovno odlučivanje i predviđanje. Informacije dobivene iz statističkih podataka nastalih primjenom statističkih metoda primjenjuju stručnjaci i donositelji odluka u svim sferama poslovanja i gospodarstva.

Poslovna statistika definira se kao znanost o metodama koje se koriste za pretvaranje podataka u smislene informacije u poslovnom okruženju sa svrhom stjecanja znanja za uspješnije odlučivanje i prognoziranje u uvjetima neizvjesnosti i rizika. Detaljnije, riječ je o skupini metoda za prikupljanje, sažimanje, odnosno uređivanje internih i eksternih podataka od interesa za poslovanje, metoda za obradu, analiziranja podataka te prikazivanja rezultata statističke analize kako bi se proizvele što solidnije informacije koje su temelj učinkovitom poslovnom odlučivanju i predviđanju. (Dumičić i Bahovec, 2011). Statističke metode u nabavi najčešće se upotrebljavaju za potrebe prognoziranja potreba nabave materijala za proizvodnju. Analitičke metode u procesu nabave zauzimaju značajnu ulogu, a koriste se za usporedbu prošlih i ostvarenih potreba s očekivanim potrebama.

Pomoću matematičkih i statističkih metoda odnosi između ekonomskih varijabli se kvantificiraju u ekonometriji. Ekonometrija sjedinjuje ekonomsku teoriju, matematiku i statistiku na način da se postavke ekonomske teorije verificiraju kroz empirijska istraživanja. Važna je za ekonomiste iz razloga što osim davanja odgovora na kvalitativne informacije (hoće li profit rasti ili padati ako proizvodnja raste, hoće li prihod rasti ili padati ako se cijena smanji i slično), menadžerima osigurava i

kvantitativne informacije (koliko će iznositi rast, odnosno pad, kolika će biti inflacija, izvoz, itd.). (Lovrić, 2005)

Prve knjige koje su se bavile tematikom ekonometrijske problematike objavljene su tek početkom šezdesetih godina prošlog stoljeća, a među najuspješnijima je J. Johnston, Econometrics Methods, koja je nakon više izdanja i danas u upotrebi. Razlog toliko kasnog začetka objavljivanja literature navedene tematike leži u tome, što čak i najjednostavnija ekonometrijska analiza zahtijeva obimna računanja. Prvi razlog pojave i početka masovnijeg korištenja ekonometrijske analize bila je recesija u razdoblju od 1981. do 1982., a drugim razlogom smatra se razvoj osobnih računala i ekonometrijske programske podrške, što je omogućilo širokom krugu poslovnih ljudi primjenu ekonometrijske analize na jednostavan način. Do osamdesetih godina prošlog stoljeća samo su velike korporacije bile u mogućnosti osnivati unutarnje specijalističke službe koje su se bavile ekonometrijskim analizama. (Lovrić, 2005)

Ekonometriju povezuju 3 discipline (Lovrić, 2005):

1. matematička ekonomija

2. ekonomska statistika

3. matematička statistika .

Ekonomske veze karakterizira stohastičnost, a kako se matematička statistika bavi podatcima koji su rezultat kontroliranih eksperimenata, potrebne su prilagodbe. Te prilagođene statističke metode nazivaju se ekonometrijske metode. Svako ekonometrijsko istraživanje odvija se po određenom tijeku (Slika 1.). (Lovrić Lj., 2005)

Slika 1 Tijek ekonometrijskog istraživanja

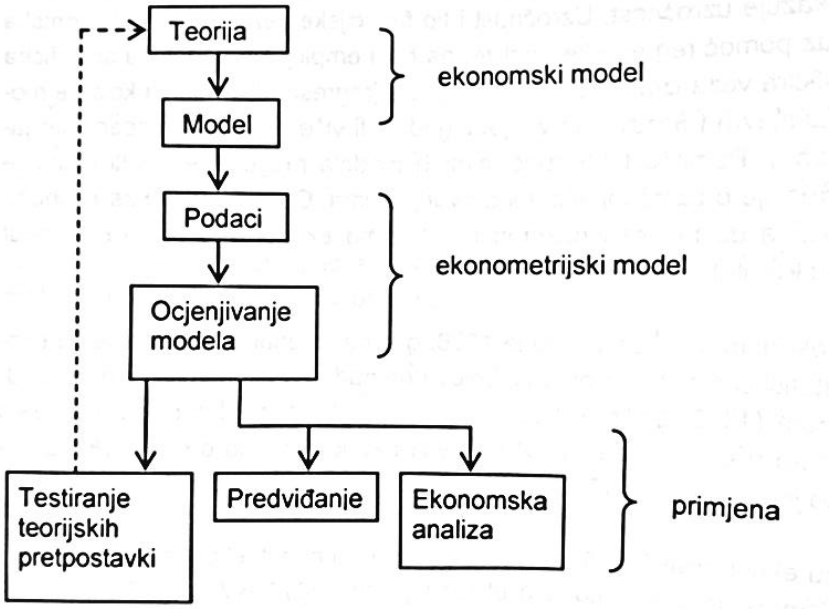

1. Izvor: Lovrić, Lj.: Uvod u ekonometriju, Rijeka, Ekonomski fakultet Sveučilišta, 2005.

Prognoziranje se može definirati kao predviđanje budućih događaja koje se zasniva na objektivnim i provjerenim činjenicama uz pomoć provjerenih znanstvenih metoda. Sastoji se u organiziranju informacija o prošlosti određene pojave kako bi se mogla predvidjeti njena budućnost. Kvantitativno prognoziranje se sastoji od korištenja različitih matematičkih modela koji se oslanjaju na prošle podatke i/ili pridružene varijable u svrhu prognoziranja budućih vrijednosti. (Berenson, 2012)

Kao i planovi, prognoze se kategoriziraju prema vremenskom horizontu za koji se vrši prognoziranje. Prema tome razlikuju se kratkoročne, srednjoročne i dugoročne prognoze. Razdoblje na koje se odnose kratkoročne prognoze jest godinu dana, no najčešće su kraće od 3 mjeseca. Njih karakterizira planiranje nabave materijala potrebnog za proizvodni proces, vremensko planiranje poslova, planiranje zapošljavanja, pridruživanje poslova te planiranje razine proizvodnje. Srednjoročne prognoze odnose se na razdoblje od tri mjeseca do tri godine te ih karakterizira izrada plana prodaje i marketinških aktivnosti, planiranje proizvodnje i budžeta, financijski planovi i analiza različitih operativnih planova. Dok se dugoročne prognoze odnose na

razdoblje od više od tri godine unaprijed te ih karakterizira razvoj novog proizvoda, kapitalne investicije, otvaranje nove ili proširenje postojeće lokacije, kao i investiranje u istraživanje i razvoj. (Šošić, 2006)

Da bi se izbjegle teškoće menadžmenta pri upravljanju poslovnim rezultatima, potrebno je izraditi model za prognoziranje i praćenje poslovnog rezultata. Prognoziranje se može obavljati primjenom povijesnih podataka te njihovim prikazivanjem u budućnosti korištenjem nekog matematičkog modela, subjektivnom procjenom ili intuitivnom pretpostavkom, kao i kombinacijom navedenih metoda. Budući da su poduzeća različitog ustroja, ne postoji univerzalni prognostički model kojim bi se na jednak način obuhvatilo sva poduzeća. Isto tako, problem mogu predstavljati ograničenja povezana s očekivanjima od prognoza. Naime, prognoze su vrlo rijetko savršeno točne, a ujedno su skupe i vremenski zahtjevne. Sukladno tome, svako poduzeće prema svojim mogućnostima i očekivanjima izrađuje model za praćenje i prognoziranje poslovnog rezultata. (Bolfek, 2005)

Kao što je navedeno, prognoziranje je vrlo važno za poduzeća, no ono je ujedno i veoma zahtjevno. U današnje vrijeme stalnih promjena i zahtjevne potražnje, skoro pa je nemoguće pravilno predvidjeti buduća događanja na tržištu. Svaka od postojećih i budućih tvrtki bori se za svoje mjesto na tržištu pa samim time ulaže u područje predviđanja potražnje i planiranja svog poslovanja sukladno tim predviđanjima.

Kod korištenja različitih metoda prognoziranja stabilnost sustava pretpostavlja da će isti uzročni sustav koji je postojao u prošlosti postojati i u budućnosti, zbog čega poduzeća često prestaju pratiti greške prognoze. Također, prognoze su u rijetkim slučajevima točne pa uvijek treba ostaviti prostora za greške. Ako se radi o grupi proizvoda, prognoza je točnija nego za pojedinačni proizvod, jer se mogućnost pogreške smanjuje.

Postoje dva osnovna pristupa prognoziranju, a to su (Bahovec i Erjavec, 2009):

- kvalitativni pristup
- kvantitativni pristup.

U kvalitativne metode prognoziranja ubraja se (Bahovec i Erjavec, 2009):

- mišljenje stručnjaka – uključuje grupu starijih vrhovnih menadžera; kombinira menadžersko iskustvo i kvantitativne prognoze te stručnjaci donose zajedničko mišljenje
- delphi metoda – uključuje grupu stručnjaka koji ne moraju biti iz jednog poduzeća te oni ne komuniciraju međusobno, već jedna osoba skuplja njihova mišljenja.
- istraživanje tržišta – oslanja se na mišljenje kupaca ili potencijalnih novih kupaca o njihovoj budućoj kupovini; koristi se za prognoziranje potražnje, pogotovo za novim proizvodima.
- prognoza prodaje – trgovački putnici daju procjene prodaja u sljedećem prognostičkom periodu.

Kvantitativne metode prognoziranja i istraživanja mogu se podijeliti u dvije osnovne skupine i to na metode prognoziranja na osnovi vremenskih serija te kauzalne prognostičke metode. Modeli vremenske serije temelje se na pretpostavci da je budućnost funkcija prošlosti te da će čimbenici koji su djelovali u prošlosti i koji djeluju u sadašnjosti nastaviti djelovati na vremensku seriju u budućnosti. Iz tog slijedi da je vremenska serija prognostička tehnika koja koristi seriju podataka iz prošlosti za izradu prognoze. Kauzalni modeli uključuju varijable ili čimbenike koji bi mogli imati utjecaja na veličinu prognoze.

Metode prognoziranja na osnovi vremenskih serija (Bolfek, 2005):

- Naivni modeli – pretpostavljaju da je razina pojave za razdoblje za koje se prognozira jednaka vrijednosti razine pojave iz posljednjeg dostupnog razdoblja.
- Modeli jednostavnih i linearnih pomičnih prosjeka – prognostička metoda koja koristi srednju vrijednost podataka za najsvježija vremenska razdoblja da bi se prognozirala potražnja za naredno vremensko razdoblje.
- Modeli jednostrukog i višestrukog eksponencijalnog izglađivanja – koriste se za prognozu pojava bez sistemskih komponenti (vremenske serije u kojima je prisutna samo iregularna komponenta).

- Standardna dekompozicija vremenske serije – pretpostavlja da se svaka pojava čije je kretanje predstavljeno u obliku vremenskog niza sastoji od više komponenata, koje su ponekad vidljive na prvi pogled, a ponekad je potrebna složenija statistička analiza da bi se te komponente utvrdile i analizirale. Najčešću dekompoziciju vremenske serije predstavljaju trend komponenata, sezonska komponenta, ciklična komponenta i slučajna (rezidualna) komponenta (Lovrić, 2008)
- Autoregresija
- Box - Jenkins metodologija

Kauzalni modeli (Bahovec i Erjavec, 2009):

- Regresijska analiza – podrazumijeva korištenje dviju varijabli kojima se izražava odnos između dviju pojava. Razlikuju se linearna i multipla regresija ovisno o broju korištenih varijabli. Regresijsku analizu možemo razlikovati kao lineranu i multiplu (oblici regresijske analize), ovisno o broju korištenih varijabli. Ipak, regresijska analiza metoda je kojoj se u ovom radu pridaje veći značaj te će iz tog razloga biti detaljnije definirana u odlomcima koji slijede.
- Strukturalni ekonometrijski modeli.

Zbog postojanja velikog broja kvantitativnih prognostičkih metoda, potrebno je često pribjeći kriterijima kojima se uspoređuje odabir optimalnog modela kao što su vjerodostojnost modela, prihvatljivost modela, moć objašnjavanja modela, ekonomičnost i efikasnost modela. Važnu stavku u prognoziranju zauzima prognoziranje matematičkim modelima za analizu i donošenje odluka o ekonomskim sistemima, no matematička rješenja su relevantna za sagledavanje stvarnih tendencija kretanja samo u mjeri u kojoj pretpostavke uključene u model zaista odražavaju stvarne odnose u ekonomiji. To ukazuje na značaj empirijskih istraživanja u ekonomiji kao sredsatva spoznaje stvarnih odnosa između pojedinih varijabli i pretpostavki koje ulaze u teorijske modele, no pojedini ekonomski procesi ne mogu se kvantificirati pa

se iz tog razloga prognoziranje u ekonomiji ograničava i vrši uz pretpostavke. (Lovrić, 2005)

2.2. Trend, korelacija i regresija

Kao što je u prethodnom dijelu rada spomenuto, statističke metode imaju važnu ulogu u poslovanju i gospodarstvu. Statistički podaci o gospodarskim kretanjima, statistički pokazatelji i modeli omogućuju praćenje gospodarskih kretanja, provođenje gospodarske politike, poslovno odlučivanje i predviđanje. Neke od osnovnih metoda su analiza trenda, korelacija i regresija. Vremenskim modelima, odnosno trendom, opisuje se razvoj pojave u vremenu. Vremenski modeli se analiziraju na temelju vremenskih serija te se zadaća statističke analize modela sastoji u njegovom oblikovanju i utvrđivanju statističko-analitičkih veličina. Korelacija omogućuje utvrđivanje povezanosti promatranih varijabli te objašnjava povezanost između pojedinih varijabli što omogućuje preciznije predviđanje ponašanja varijabli. Korelacija je ujedno i polazišna osnovica za složenije statističke elaboracije. Regresijski model predstavlja algebarski model kojim je izražen odnos između pojava te se često primjenjuje za potrebe predviđanja. Primjenjuje se u mnogim stručnim i znanstvenim područjima te je, kao i svaki model, pojednostavljena slika stvarnih pojava.

Trend

„Za potrebe prognoziranja budućih kretanja određene pojave upotrebljava se analiza podataka prijašnjih vremenskih razdoblja. Prognoziranje budućih kretanja može biti kratkoročno, dugoročno i srednjoročno. Kratkoročne prognoze su prognoze za vremensko razdoblje od jedne godine, srednjoročne dvije do pet godina, dok se dugoročne prognoze odnose na vremenska razdoblja duža od pet godina. Skup kronološki utvrđenih vrijednosti varijable koja predočuje neku pojavu ili statistički proces u vremenu je vremenski niz.“ (Šošić, 2006)

Veličine Y_t za t= 1, 2 , …n koje tvore niz nazivaju se frekvencije. Razlikujemo dvije vrste vremenskih nizova s obzirom na vremensku definiciju (Papić, 2014):

1. Intervalni vremenski niz – veličina pojave mjeri se unutar određenog vremenskog intervala (npr. broj noćenja tijekom cijele godine u razdoblju od 1991. do 2000. godine)
2. Trenutačni vremenski niz – mjerenje ili promatranje pojave vrši se u određenom trenutku (npr. broj stanovnika općine Slavonski Brod u razdoblju od 1971. do 2001. godine – stanje sredinom godine).

Dinamiku vremenskog niza možemo promatrati preko apsolutnih i relativnih pokazatelja te preko prognostičkih trend-modela. Prognostički trend-modeli su vrlo slični regresijskim modelima, s tim što je kod trend-modela nezavisna varijabla uvijek vrijeme (izraženo u godinama, mjesecima, tjednima, danima…). Ako postoji neka pravilnost u promjenama vrijednosti promatrane pojave u određenom vremenskom razdoblju, vremenski niz ima tendenciju rasta ili pada, takav niz ima trend i tada se kretanje promatrane pojave može prikazati pomoću trend-modela. Model linearnog trenda objašnjava linearno kretanje (pozitivno ili negativno) vrijednosti promatranog vremenskog niza kroz vrijeme. Osim prikaza linearnog kretanja pojave vremenskog niza, na temelju ocijenjenog modela može se vršiti predviđanje vrijednosti pojave za neka buduća razdoblja. U teoriji, mogućnost korištenja metode trenda postoji uvijek kada postoji vremenski niz, no u praksi, za primjenu linearnog trenda najpogodniji su dugoročni vremenski nizovi s jednogodišnjim vremenskim razdobljima. Model linearnog trenda se zapisuje u općenitom obliku((Papić, 2014):

$$\hat{Y} = bX + a \quad \text{ili} \quad Y = \hat{Y} + u \tag{2. 1}$$

$$b = \frac{\sum_{t=1}^{N} x_t y_{t-N x \bar{X}\ x\ \bar{Y}}}{\sum_{t=1}^{N} x_t^2 - N\ x\ \bar{X}^2} \tag{2. 2}$$

$$a = \bar{Y} - b \text{ x } \bar{X} \tag{2. 3}$$

Gdje je:

Y – vrijednost vremenskog niza (originalni podatci vremenskog niza); ovisna varijabla,

$\hat{Y}$ – procijenjena vrijednost (trend podatci)

X – vrijeme; neovisna varijabla,

u – dio varijance varijable Y koji nije objašnjen utjecajem varijable X.

b - vrijednost parametra *b* predstavlja prosječno povećanje-smanjenje varijable Y u jedinici vremena.

a - parametar *a* predstavlja očekivanu vrijednost varijable Y ako je $x_t = 0$ (u ishodištu vremenskog razdoblja).

Nakon procjene parametara modela trenda odnosno nakon što smo odredili jednadžbu modela linearnog trenda potrebno je utvrditi reprezentativnost, točnije objašnjava li model kretanje ovisne varijable vremenskog niza Y kroz vrijeme X. Reprezentativnost modela trenda prosuđuje se apsolutnim i relativnim pokazateljima, odnosno korištenjem varijance, standardne devijacije i koeficijenta varijacije.

Vrijedi da je (Biljan-August, Pivac i Štambuk, 2009):

$$SP = \sum_{t=1}^{n}(\hat{Y}_t - \bar{Y})^2 = \hat{\beta}_0 \times \sum_{t=1}^{n} Y_t + \hat{\beta}_1 \times \sum_{t=1}^{n} X_t\, Y_t - n \times Y^2 \quad (2.4)$$

$$SR = \sum_{t=1}^{n}(Y_t - \hat{Y}_t)^2 = \sum_{t=1}^{n} Y_t^2 - \hat{\beta}_0 \times \sum_{t=1}^{n} Y_t - \hat{\beta}_1 \sum_{t=1}^{n} X_t\, Y_t \quad (2.5)$$

$$ST = \sum_{t=1}^{n}(Y_t - \bar{Y})^2 = \sum_{t=1}^{n} Y_t^2 - n \times \bar{Y}^2 \quad (2.6)$$

gdje je:

SP – protumačeni dio ukupne sume kvadrata odstupanja vrijednosti varijable vremenskog niza Y od aritmetičke sredine,

SR – rezidualni (ne protumačeni) dio ukupne sume kvadrata odstupanja vrijednosti varijable Y od aritmetičke sredine,

ST – ukupna suma kvadrata odstupanja vrijednosti varijable vremenskog niza Y od aritmetičke sredine

Iz navedenog proizlazi da je:

$$SP + SR = ST \quad (2.7)$$

što je izraz za jednadžbu analize varijance, a ujedno i temelj analize reprezentativnosti trend modela.

Apsolutni pokazatelj reprezentativnosti linearnog trend modela je standardna pogreška trend modela, odnosno standardna devijacija trenda koja iskazuje prosječni stupanj varijacije stvarnih vrijednosti ovisne varijable u odnosu na očekivane trend vrijednosti:

$$\hat{\sigma} = \sqrt{\frac{\sum_{t=1}^{n}(y_t - \hat{y}_t)^2}{N-2}} \quad \text{ili} \quad \hat{\sigma} = \sqrt{\frac{SR}{n-2}} \tag{2.8}$$

Navedeni pokazatelj se izražava u originalnim jedinicama mjere varijable vremenskog niza Y te je na temelju istoga teško uspoređivati reprezentativnost modela s različitim mjernim jedinicama. Zbog toga se koristi relativni pokazatelj koeficijent varijacije trend modela koji iskazuje postotak standardne pogreške trenda od aritmetičke sredine varijable Y:

$$\hat{V}_{\hat{y}} = \frac{\hat{\sigma}_{\hat{y}}}{\bar{Y}} \times 100 \tag{2.9}$$

Reprezentativnost modela je veća što je vrijednost koeficijenta varijacije bliže 0. Na temelju analize varijance izračunava se koeficijent determinacije. Koeficijent determinacije je omjer zbroja kvadrata odstupanja protumačenih trend modelom i sume kvadrata ukupnih odstupanja. Koeficijent determinacije pokazuje koliko % je sume kvadrata odstupanja vrijednosti varijable Y od aritmetičke sredine protumačeno trend modelom. Trend model je reprezentativniji što je ovaj pokazatelj bliži 1. Koeficijent determinacije se izračunava na sljedeći način:

$$r^2 = \frac{SP}{ST} = 1 - \frac{SR}{ST} \tag{2.10}$$

Reprezentativnost modela trenda je veća u slučajevima kada postoje male razlike između originalnih vrijednosti vremenskog niza i trend vrijednosti.

Trend vrijednosti koje se dobiju izračunom predstavljaju nove vremenske nizove koji se promatraju kao teorijski podaci promatrane pojave. Na temelju izračunatih podataka predviđa se kretanje promatrane pojave i naziva se ekstrapolacija trenda. Ekstrapolacijom trenda moguće je predvidjeti kretanja pojave u budućnosti, ali s pretpostavkom da se svi čimbenici koji utječu na kretanje pojave razvijaju u istom smjeru i približno istim intenzitetom. Ekstrapolacija trenda izračunava se tako da se u jednadžbu linearnog trenda umjesto koeficijenta X koji označava vremensko razdoblje uvrsti vrijednost za koju se želi izračunati neka buduća vrijednost. U radu će se koristiti metoda linearnog trenda za buduća predviđanja potreba materijala. (http://www.efos.unios.hr/imijoc/wp-content/uploads/sites/71/2013/09/Primjena-statisti%C4%8Dkih-metoda-s-naglaskom-na-trend-korelaciju-i-regresiju.pdf, preuzeto 01.02.2018.)

Korelacija

Korelacijska analiza utvrđuje i opisuje smjer i snagu linearne povezanosti dviju varijabli. To je brojčani pokazatelj jakosti i smjera veze između promatranih pojava odnosno varijabli. Kada se govori o vezi između dvije varijable obično se razlikuje nezavisna varijabla X i zavisna varijabla Y. Prema smjeru povezanosti razlikuju se pozitivna i negativna povezanost tj. koeficijent poprima vrijednosti između -1 i 1 i označava se s *r*. Pozitivan koeficijent korelacije ukazuje na upravnu proporcionalnost varijabli X i Y tj. rast jedne varijable uzrokuje rast druge varijable i obrnuto. Negativni koeficijent korelacije ukazuje na obrnutu proporcionalnost tj. rast jedne varijable uzrokuje pad druge varijable i obrnuto.

Apsolutna vrijednost koeficijenta korelacije ukazuje na način povezanosti između varijabli. Što je *r* bliže nuli, povezanost je slabija, a što je bliža jedinici, povezanost je jača. (Papić, 2014.)

Regresija

Regresijska analiza je najčešće korištena metoda u empirijskim istraživanjima. Za razliku od korelacijske analize u kojoj se istražuje smjer i jakost povezanosti dviju varijabli x i Y, u regresijskoj analizi želi se procijeniti prosječna vrijednost jedne varijable y na temelju zadanih vrijednosti druge varijable x. Cilj je regresijske analize

vezu između promatranih varijabli izraziti ili opisati odgovarajućim analitičko matematičkim izrazom, tj. regresijskim modelom. Osnova regresijske analize je regresijski model. Regresijski model je hipotetički model (formula) kojim se izražava statistička (stohastička) povezanost između pojava. Na temelju uzorka vrijednosti odabranih varijabli procjenjuju se parametri pretpostavljenog modela i testiraju pretpostavke kako bi se odredila adekvatnost procijenjenog modela. Ako je procijenjeni model adekvatan, koristi se za testiranje ekonomske teorije i u prognostičke svrhe. (Bahovec i Erjavec, 2015).

Regresijska se analiza dijeli na jednostavnu (u kojoj se promatra utjecaj promjene jedne varijable na promjenu druge) te višestruku (koja podrazumijeva odnos više nezavisnih varijabli s jednom zavisnom).

Faze provođenja regresijske analize su (Dumičić i Bahovec, 2011):

- definiranje problema istraživanja
- specifikacija regresijskog modela
- procjena parametara i drugih statističko-analitičkih pokazatelja
- regresijska dijagnostika – provjera statističko-teorijskih pretpostavki primjene modela
- interpretacija i primjena modela.

Model jednostavne linearne regresije je statistički model za koji se pretpostavlja da je zavisna varijabla Y slučajna varijabla povezana s nezavisnom varijablom x. Ukoliko ravnomjeran rast varijable X prati i ravnomjeran rast (pad) varijable Y (što se vidi i iz dijagrama rasipanja), model koji će odgovarati promatranoj vezi je model jednostavne linearne regresije, a opći oblik tog modela je (Papić, 2014):

$$Y = \beta_0 + \beta_1 X + u \qquad (2.11.)$$

Gdje je u dio varijance varijable Y koji nije objašnjen utjecajem varijable X. Cilj nam je odrediti parametre u linearnoj funkciji (jednadžba pravca regresije):

$$\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 X + \mathrm{u} \qquad (2.12.)$$

Tako da dobiveni pravac što bolje aproksimira skup točaka u dijagramu rasipanja. Parametri $\hat{\beta}_0 \, i \, \hat{\beta}_1$ se određuju metodom najmanjih kvadrata. Metoda najmanjih kvadrata sastoji se u određivanju onih procjena nepoznatih parametara koji minimiziraju zbroj kvadrata odstupanja stvarnih vrijednosti zavisne varijable od procijenjenih vrijednosti. Regresijski koeficijent $\hat{\beta}_1$ određuje nagib regresijskog pravca, a $\hat{\beta}_0$ je konstantni član.

$\hat{\beta}_1$ pokazuje kolika je linearna promjena regresijske (očekivane) vrijednosti zavisne varijable za jedinično povećanje nezavisne varijable x. $\hat{\beta}_1$ je iznos za koji se linearno mijenja prosječna vrijednost zavisne varijable ako se nezavisna varijabla poveća za jednu mjernu jedinicu.

$\hat{\beta}_0$ je konstantni član i regresijska je vrijednost zavisne varijable za $x_i = 0$. Formalna interpretacija konstantnog člana nema uvijek suvislo značenje i u takvim se slučajevima ne interpretira. (Papić, 2014.)

3. Pojam i svrha nabave

Nabava je funkcija i djelatnost poduzeća i drugih poslovnih sustava, koja brine o opskrbi materijalima, opremom, uslugama i energijom potrebnima za realizaciju ciljeva poslovnog sustava. Često se poistovjećuje s kupnjom. Kao djelatnost je izuzetno složena i značajna za uspješnost poslovanja poduzeća. Pretpostavke za efikasno obavljanje te djelatnosti su raznovrsna ekonomska i tehnička znanja te poznavanje psihologije. U uvjetima globalizacije potrebno je poznavanje informacijskih tehnologija, stranih jezika te osobitosti kulture i običaja zemalja dobavljača – partnera u poslovanju. (Ferišak, 2006)

Ljudi često pojam „nabave“ zamjenjuju s kupnjom, također su skloni nabavu poistovjećivati s materijalnim poslovanjem te logistikom. U literaturi se često mogu pronaći pojmovi kao što su marketing nabave, opskrba te dobava. Međutim, ti pojmovi nisu istoznačnice, već svaki od njih ima drugačije značenje i funkciju. Stoga je potrebno svaki od tih pojmova pobliže objasniti. Velik je broj razloga zbog kojih treba te pojmove razgraničiti. Neki od tih razloga su značenje materijalnog poslovanja, opskrbe i logistike za racionalizaciju troškova i sigurnost odvijanja procesa protoka roba između tržišta nabave i potrošača. Još jedan veliki razlog jest značajno značenje nabave s aspekta troškova i uspostavljanja odnosa s tržištem nabave. S obzirom na funkcije koje nabava sadrži te aspekte objekta nabave, pojam „nabava“ ili „dobava“ može se opisati u užem i širem smislu.

3.1. Nabava u užem smislu

„S aspekta funkcija što ih sadrži, pod nabavom u užem smislu (eng. Procurement, njem. Die Beschaffung; die Anshcaffung) podrazumijeva se odvijanje operativnih poslova u procesu pribavljanja objekata nabave. To su poslovi koje je potrebno svakodnevno obavljati da bi se pravodobno realizirale definirane potrebe i zahtjevi opskrbe poslovnog sustava za objektima nabave odgovarajuće kakvoće, u potrebnoj količini, po primjerenim cijenama, rokovima, na određenom mjestu i uz odgovarajući servis.“ (Ferišak, 2006)

Operativni poslovi nabave jesu (Ferišak, 2006):

- ispitivanje i objedinjavanje zahtjeva za nabavu dobivenih od pripreme rada, razvoja i drugih organizacijskih jedinica,
- promatranje i praćenje tržišta nabave,
- izrada i postavljanje upita dobavljačima,
- prijam, ispitivanje i ocjena ponuda dobavljača,
- vođenje pregovora s dobavljačima,
- izbor najpovoljnije ponude i naručivanje,
- praćenje rokova isporuke i komunikacija s dobavljačima,
- kontrola računa dobavljača,
- suradnja s ostalim službama poduzeća,
- reklamacije zbog neodgovarajućeg izvršenja obveza dobavljača,
- vođenje evidencija/datoteka nabave.
- kontrola zaliha
- izvještavanje, praćenje ušteda.

Zbog neizvjesnosti i nepredvidljivosti tržišta, nerijetko dolazi do komplikacija u procesu nabave pa je samim time zbog kratkih rokova otežano kvalitetno obaviti sve operativne poslove. Kako izvršavanje operativnih poslova zahtjeva određeno vrijeme, uz to se često javljaju različiti problemi i poteškoće. Neki od tih problema su isporuka krive robe, neodgovarajuće robe koja može biti prema vrstama, kakvoći ili kvaliteti, robe s greškom, problemi s isporukom robe, reklamacije, plaćanja te problemi pravovremenog naručivanja. Najčešći posao u praksi zaposlenika je takve greške pravovremeno uočiti kako bi se na najlakši i najpovoljniji način one izbjegle te u samom početku otklonile. Također, zaposlenici se bave i operativnim poslovima s ciljem otklanjanja problema. S gledišta objekta, nabava u užem smislu može se okarakterizirati kao skup poslova nabave materijala, sirovina, pomoćnih i pogonskih materijala, sklopova, dijelova, kompleksnih poslovnih procesa te trgovačke robe.

3.2. Nabava u širem smislu

„Nabava u širem smislu (engl. Purchasing; Acquisition; Sourcing; Supply Management, njem. Der Einkauf) obuhvaća i strategijske zadatke (eng. Advanced Purchasing) o kojima ovise učinci i dobit poslovnog sustava. Zadaci nabave u širem smislu su da pripremi što bolje korištenje mogućnosti tržišta nabave, da pozitivno utječe na proizvodnu potrošnju i prodaju definiranjem vrsta, oblika i strukture ulaza (inputa) uz korištenje potencijala dobavljača i vodeći računa o zaštiti okoliša, s ciljem da se što bolje zadovolje zahtjevi potrošača te da se maksimiziraju učinci i dobit poslovnog sustava.“ (Ferišak, 2006)

Važan zadatak nabave je i obavljanje strategijskih zadataka koji u osnovi imaju cilj sniziti troškove nabavljanja robe te što učinkovitije poslovanje nabave i cijelog sustava. U strategijske zadatke se ubraja planiranje nabave, kontroling nabave, izračunavanje ekonomičnih količina nabave, istraživanje tržišta nabave, kooperacija u nabavi, stohastičko i determinističko istraživanje, suradnja kod razvoja novih proizvoda, zadaci benchmarkinga, izračunavanje i praćenje trendova ponude i potražnje na tržištu nabave, trendova cijena, analize dobavljača te primjena ABC-XYZ analize.

Drugim riječima velik dio zadataka nabave odnosi se na istraživanje nabave. Preciznije, na organizirano i kontinuirano istraživanje svih determinanta značajnih za pripremu i optimizaciju nabave. Istraživanje nabave podrazumijeva primjenu različitih znanstvenih metoda te sustavno praćenje i ocjenjivanje podataka i na samom kraju optimalno kombiniranje u cilju stvaranja temelja odgovarajućeg odlučivanja.

Kako bi se postigli unaprijed zadani ciljeve kao npr. sniženje troškova te povećanje učinaka nabave, djelatniku nabave potrebna su znanja s područja primjene statističkih metoda, ekonomske analize, organiziranja, linearnog programiranja, kontrolinga, revizije i drugo.

3.3. Zadaci nabave

Zadaci nabave u proizvodnom poduzeću su nabaviti materijale u odgovarajućoj kvaliteti, odgovarajuće količine, u pravo vrijeme, uz najpovoljnije cijene, uz najpovoljnije uvjete plaćanja, od odgovarajućih dobavljača te uz najniže troškove. Nabava bi se trebala odvijati tako da se potpuno eliminiraju zastoji u proizvodnji zbog nedostatka materijala, ali ne znači uz povećane zalihe materijala. Treba nastojati da se proizvodnji omogući kontinuiran rad sa što manjim prosječnim zalihama materijala, odnosno sa što manje angažiranih financijskih sredstava za zalihe materijala. Dobrim nabavnim poslovanjem smanjuju se i eliminiraju troškovi koji nastaju zbog visokih zaliha, zastarjelosti materijala i gubitaka materijala zbog rasipa ili oštećenja. Nabava svojim poslovanjem i rezultatima rada može utjecati na rezultat poslovanja cijelog poduzeća, a s obzirom na troškove materijala taj utjecaj je u proizvodnim poduzećima vrlo velik.

Za uspješno i ekonomično vođenje nabave, zadaci nabave mogu se definirati ovako (Ferišak, 2006):

- vanjska i unutarnja organizacija nabave,
- istraživanje tržišta nabave,
- planiranje nabave materijala,
- utvrđivanje količine materijala za nabavu,
- naručivanje materijala,
- praćenje izvršenja narudžbi materijala,
- primanje, kvalitativna i kvantitativna kontrola materijala,
- evidencija nabave,
- kontrola i analiza nabave.

U budućnosti se od nabavnog odjela može očekivati više od niskih cijena robe i izbjegavanja problema, očekuje se nabava koja doprinosi stvaranju vrijednosti.

3.4. Ciljevi nabave

„Ciljevima se definiraju stanja koja se žele ostvariti, održati ili spriječiti. Kada su ciljevi poznati, onda se mogu svrhovito usmjeravati na poslovne aktivnosti. Dakle, ciljevima se definiraju stanja koja se žele ostvariti, održati ili spriječiti.“ (Ferišak, 2006)

Opći ciljevi nabave u klasičnoj nabavi

Kako bi se ostvario opći cilj maksimiziranja dobiti, potrebno je postaviti i ciljeve nižeg reda. Nije dovoljno da se postavi samo opći cilj maksimiziranja dobiti, zato što je to preopćenito te je teško ići prema takvome cilju bez ikakvih potciljeva ili smjernica. Potrebno je postaviti što više potciljeva jer će oni uvelike pomoći pri dugoročnom ostvarivanju općeg cilja. Nabava će pridonijeti tome cilju tako što će interne korisnike opskrbiti materijalima i uslugama najpovoljnijima na tržištu. Način na koji će to učiniti jeste kroz snižavanje nabavnih cijena različitih materijala i usluga te pronalaska optimalnih dobavljača.

Opći ciljevi nabave u suvremenoj nabavi

U suvremenoj nabavi sniženje troškova nabave materijala i usluga je samo jedan od ciljeva.

Kako bi se ostvarile koristi ne samo za vlastito poduzeće, već i za dobavljače i kupce, potrebno je troškove promatrati u cijelosti. Napredak čovječanstva dovodi do spoznaje da je društveno odgovorno poslovanje izrazito bitan aspekt svakog poduzeća. Upravo iz toga proizlazi potreba za postavljanjem ekoloških ciljeva. Takvi ciljevi se ostvaruju već kod nabave materijala te se postavlja pitanje hoće li se proizvod moći reciklirati ili povoljno zbrinuti.

U suvremenom poslovanju opći su ciljevi da se pribave materijali i usluge (Ferišak, 2006):

- funkcionalno odgovarajuće kakvoće,

- po najpovoljnijoj cijeni,
- u ekonomičnoj količini,
- u pravo vrijeme,
- s najpovoljnijih izvora,
- uz visoki servis isporuke,
- uz postizanje najveće moguće zaštite okoliša i prirodnih resursa,
- uz najmanje rizike,
- uz najniže troškove,
- uz dobre odnose s dobavljačima.

3.5. Značenje nabave

Sve je veći značaj nabave u privatnim i javnim poduzećima i institucijama s tendencijom dublje društvene podjele rada. Broj dobara i usluga što se nabavljaju tzv. outsourcing izrazito raste, ponajviše zbog modularne proizvodnje. Upravo to dovodi do većeg udjela vrijednosti nabavljenih materijala i usluga u prodajnoj cijeni proizvoda. U proizvođačkim poduzećima udio materijala i usluga u prodajnoj cijeni proizvoda u prosjeku iznosi oko 60%. Ovi podaci karakteristični su za razvijene zemlje u kojima se udio plaća u prodajnoj cijeni proizvoda kreće između 10-35%, odnosno u prosjeku 20%. Kod nerazvijenih zemalja udio vrijednosti materijala u prodajnoj cijeni proizvoda veći je na račun znatno manjeg udjela plaća.

Relativno male uštede u vrijednosti materijala i usluga dovode do značajnih povećanja dobiti poduzeća upravo zbog velikog udjela vrijednosti materijala i usluga u prodajnoj cijeni proizvoda. Poznato je da su troškovi organizacijske jedinice izrazito mali (2-4%) od ukupnih troškova nabave, stoga je korisno da se u nabavi zaposli dovoljan broj visoko-stručnih djelatnika te da se uz obavljanje operativnih zadataka počne znatno više pozornosti pridavati strategijskim i marketinškim zadacima nabave. Bez tih zadataka se ne mogu značajnije iskoristiti velike mogućnosti ušteda. (Ferišak, 2006)

3.6. Svrha nabave

Često se svrha nabave tumači kao ostvarivanje ciljeva vezanih sa samom opskrbom organizacije, čiji je nabava zapravo dio. To se ostvaruje kroz potrebna sredstva, usluge te pomoću energije koje se ne proizvode u vlastitoj režiji. Vrlo je važno voditi računa da opskrba bude odgovarajuće kakvoće, kvalitete i kvantitete po povoljnim cijenama. Da se ne kasni s isporukama te da su isporuke ugovorene u pravo vrijeme i na pravom mjestu, a sve to od dobavljača koji su pouzdani tj. koji savjesno izvršavaju obveze. Drugim riječima, svrha nabave jest povezivanje i usklađivanje potrebe vlastite organizacije za potrebnim sredstvima, energijom, resursima te uslugama s interesima dobavljača s kojima posluje. Uravnotežiti ciljeve nije uvijek najjednostavnije. Međutim, donositelj odluke nastoji uravnotežiti ciljeve te pronaći optimalna rješenja kako bi ostvario što bolju opskrbu.

Navedeno se ostvaruje kroz sljedeće (Ferišak, 2006.):

- kontinuirano zadovoljavanje potreba vlastite organizacije, pritom vodeći računa o održavanju dobrih poslovnih odnosa s dobavljačima
- razviti što veći broj alternativnih izvora nabave
- poštivanjem etičkih načela
- organizirati načine, takve koji će poštivati zakone ekonomičnosti i sigurnosti
- uspostaviti odnose s drugim poslovnim funkcijama

3.7. Strategije nabave

"Strategija nabave se može definirati kao skup pravila, sredstava i putova ostvarenja ciljeva nabave, kojima se na duži rok osigurava ili poboljšava doprinos nabave stvaranju vrijednosti i uspješnosti poslovanja poduzeća." (Ferišak, 2006.). U funkcionalno orijentiranoj organizaciji, nabava je bila zasebna funkcija koja je obavljala unaprijed strogo propisane zadatke i brinula se da u pravo vrijeme opskrbi poduzeće potrebnim dobrima i uslugama uz što niže troškove. Kod suvremene organizacije to je nešto drugačije. Danas se fokus stavlja na kreiranje strategije nabave koju definira skup pravila, sredstava te putova kojima će se cilj nabave ostvariti.

Drugim riječima poboljšavaju se doprinosi nabave te odnosi s dobavljačima koji stvaraju dodanu vrijednost i pospješuju rad organizacije u cjelini. Uspostavljanjem što boljeg odnosa i suradnje s dobavljačima, poduzeće nastoji integrirati usluge ili proizvode dobavljača u procese stvaranja vrijednosti. Cilj tome jest izbjegavanje nepotrebnih poslova u procesima proizvodnje partnera koji bi nam mogao oduzeti mnogo vremena.

Zadatak je dobavljača baviti se kompleksnim problemom inovacija proizvoda kupaca i procesa stvaranja vrijednosti u cijelom logističkom lancu, ako na taj način mogu cjelokupno poboljšati rješavanje vlastitih problema te ako su stimulirani za provedena unaprjeđenja. Takvo povezivanje aktivnosti naziva se vertikalno povezivanje. Ono nam omogućuje povezivanje svih stupnjeva procesa stvaranja vrijednosti koje bi u konačnici donijelo profit za sve sudionike. Optimalno bi bilo da nabava i dobavljači surađuju na što većoj razini. Međusobnom razmjenom informacija o razvoju proizvoda te rokovima isporuka uvelike će pridonijeti planiranju kvalitetnije suradnje koja je često povezana i s investicijama. Kvalitetan odnos s dobavljačima ključnih resursa od značajne je važnosti kako se ne bi ugrozio uspostavljeni način opskrbe te se s istima sklapaju dugoročni ugovori u cilju stvaranja partnerstva. U suvremenom poslovanju javlja se trend smanjenja broja izravnih dobavljača. Odlučuje se hoće li se roba nabaviti s jednog izvora ili će se roba naručivati od više dobavljača. Kod nabave robe od jednog dobavljača javlja se rizik neizvršenja obveze na vrijeme dok s druge strane takav oblik omogućava znatnu uštedu. Upravo zato u kooperaciju se ulazi samo sa sposobnim i inovativnim dobavljačima koji imaju konkurentske prednosti na tržištu.

Kada se govori o strategiji nabave s više izvora, podrazumijeva se nabava predmeta niže kompleksnosti koje na tržištu u pravilu nudi nekoliko ili niz dobavljača. Sklapaju se ugovori s više dobavljača unatoč činjenici da postoji jedan dobavljač s najpovoljnijim uvjetima. Instrument kojim se utječe na dobavljače jest dati na znanje da postoji mogućnost promjene dobavljača zbog nepovoljnih uvjeta ili zbog nepoštivanja ugovornih obveza. Podrazumijeva se da ova strategija ima učinak samo kada na tržištu ima dovoljan broj dobavljača. (Ferišak, 2006)

3.8. Operativno planiranje nabave

Planiranjem se nastoje spriječiti budući problemi opskrbe. Planiranje nabave kreće od istraživanja i definiranja korisnika te procjenom uvjeta okruženja koji su značajni za ostvarenje ciljeva nabave. Sljedeći korak je planiranje nabavljanja i zaliha. Sam proces započinje planiranjem kojeg slijede odlučivanje, organiziranje, upravljanje i kontrola.

„Dobro planiranje anticipira probleme prije njihova nastanka i na taj se način eliminira stihija te stvaraju uvjeti za veću vjerojatnost efikasnog postizanja ciljeva i uspješnog razvoja poduzeća“ (L. Stihović u knjizi: V. Ferišak, 2006. – L. Stihović)

Planove nabave može se prema sadržaju podijeliti na (Ferišak, 2006):

- planove nabave dobara i usluga, koja/koje se pribavljaju kontinuirano u skladu s potrebama proizvodnje i/ili prodaje;
- planove nabave dobara i usluga koja/koje se nabavljaju periodično;
- planove nabave dobara i usluga koja/koje je potrebno nabaviti jednokratno;
- planove troškova funkcije nabave (osoblja, prostora, uređaja i dr.)

Robe i usluge koje su potrebne za realizaciju programa proizvodnje i prodaje bez obzira troše li se u planskom razdoblju jednomjerno ili ne, nabavljaju se kontinuirano. Kod takvih potreba vrlo je važno precizno prognozirati. Drugim riječima, istražiti prema vremenu, kakvoći i količinama kako bi plan mogao poslužiti kao podloga raznih aktivnosti nabave. Dok se s druge strane planovi periodične nabave odnose na dobra male vrijednosti koja se drže na zalihama, na pribavljanje potrošnih materijala, manjih strojeva te uređaja s kratkim vijekom uporabe. Planovi jednokratne nabave pak se odnose na dobra i usluge o čijoj nabavi odlučuje rukovodstvo poduzeća. Tu ulaze strojevi, građevinski objekti, prava, usluge i sl. Za takvu nabavu potrebno je izraditi proračun ekonomičnosti njihova korištenja. Naravno postoje i planovi troškova funkcije nabave koji sadrže podatke o predviđenim troškovima nabave službe. Primjeri takvih troškova su osobni dohoci zaposlenika, troškovi korištenja prostorija i uređaja, informacijski i telekomunikacijski troškovi, troškovi putovanja, dnevnice i sl. Planovi nabave moraju biti usklađeni s ciljem, strategijama i planovima poduzeća.

Metode istraživanja potreba za predmetima rada

Postoje velike prednosti ukoliko se potrebe za predmetima rada istraže što preciznije. No valja istaknuti da to nije uvijek moguće zbog nesigurnosti prognoza prodaje i proizvodnje dobara, a posebice za one stavke čiji je udio u ukupnoj vrijednosti objekata vrlo malen. Razlikuju se tri skupine metoda istraživanja, potreba i stupnja preciznosti rezultata. Prva skupina metoda su deterministčke metode; koje su orijentirane programima prodaje i proizvodnje. Zatim postoje stohastičke metode; one pak su orijentirane na prošlu potrošnju te zadnje heurističke metode, koje se temelje na subjektivnoj procjeni potreba.

Deterministčke metode

„Podloga za deterministčko istraživanje potreba su jednoznačni, potpuni i točni opisi proizvoda, koje se može napraviti na različite načine. Najčešće se koriste tehnički opisi proizvoda i to nacrti i sastavnice proizvoda.“ (Ferišak, 2006.) U deterministčke metode ubrajamo egzaktno utvrđivanje potreba prema količinama, vrstama i rokovima korištenja materijala na temelju programa proizvodnje. One se uglavnom koriste za netipične materijale s velikim udjelom u ukupnoj vrijednosti potrošnje. Nacrti u grafičkom obliku prikazuju sastav proizvoda u određenom mjerilu ili pomoću normiranih simbola te se sastav kompleksnih proizvoda ne može prikazati samo jednim nacrtom pa se nacrti hijerarhijski raščlane.

U tom slučaju, s obzirom na sadržaj, razlikujemo (Ferišak, 2006.):

- nacrte proizvoda, kojima se prikazuju komponente/sklopovi;
- nacrte sklopova, kojima se prikazuje sastavne dijelove sklopova;
- nacrte dijelova, kojima se prikazuju njihovi sastavni elementi, tj. vrste i količine materijala.

Sastavnice pak prikazuju strukturu proizvoda u obliku liste, u kojoj su navedeni bitni podaci o proizvodu i njegovim komponentama (materijalima, dijelovima i sklopovima). Sastavnice možemo razvrstati prema strukturi, sadržaju, primjeni te načinu provedbe izmjena u njima. Temeljni oblik sastavnice je tzv. skupna sastavnica, koja sadrži šifru i naziv proizvoda ili sklopa na koji se odnosi, podatke o komponentama (sastavnim dijelovima i materijalima) od kojih se sastoji proizvodni

sklop i o količinama potrebnih komponenata, izraženih brojem komada. Na temelju sastavnica, u kojima su analitički prikazane komponente proizvoda, može se napraviti pregled potrebnih materijala, dijelova i sklopova u pojedinim proizvodima.

Za što kvalitetniji i optimalniji rad nabave vrlo je važno da su pojedini predmeti šifrirani na način da ih se može nedvosmisleno identificirati te da imaju jednoznačne nazive. Da imaju određene mjerne jedinice s kojima se vode u sastavnicama te da imaju oznaku načina pribavljanja (vlastita proizvodnja, od dobavljača itd.) Vrlo je važno da imaju navedene tehničke podatke (težina, dimenzije i sl.).

Stohastičke metode

Potrebe se istražuju na temelju podataka o potrošnji u prošlim razdobljima, pomoću statističkih metoda. Stohastičke se metode koriste za standardne materijale s malenim udjelom u ukupnoj vrijednosti potrošnje. Stohastičke se metode koriste za istraživanje potreba standardnih materijala malene vrijednosti koji se troše u raznim fazama procesa proizvodnje, a razdoblje njihove potrošnje (od trenutka njihove prve primjene u procesu proizvodnje do zadnjeg koraka toga procesa proizvodnje u kojem su potrebni kao predmeti rada) duže je od vremena potrebnog za njihovu nabavu.

„Za pretežni dio, tj. za 70-80% predmeta rada ne bi bilo ekonomično ili nije moguće koristiti determinističke metode potreba. Tu je većinom riječ o materijalima koji su ABS analizom razvrstani u skupinu C te o ponoćnim i pogonskim materijalima koje nabava drži na zalihi, za njih ima utvrđene normative zaliha i samostalno istražuje potrebe.“ (Ferišak, 2006)

Zaposlenici u nabavi u takvim slučajevima često postupaju vrlo jednostavno. Kako bi odredili potrebnu količinu materijala pojedinačno se uzima prosjek potrošnje zadnjih nekoliko mjeseci i tome se svakog mjeseca dodaje potrošnja prošlog mjeseca, a isključuje se najstariji podatak o potrošnji. Prosjek potrošnje su prognozirane potrebe količine narednog mjeseca.

Međutim, to je zadovoljavajući način utvrđivanja budućih potreba samo u određenim slučajevima. Potrošnja i zalihe imaju različitu dinamiku, stoga je potrebno izabrati postupke procjene budućih potreba koji će pratiti tendenciju razvoja potreba,

a posebno valja razlikovati slučajeve kad je riječ o redovitim potrebama i slučajeve kada je riječ o sezonskim potrebama koje jako variraju.
Kod redovitih potreba, razlikujemo konstantne ili pak potrebe s trendom rasta ili pada. S druge strane kod neredovitih potreba dolazi do većih odstupanja potrošnje od godišnje prosječne vrijednosti. Svakoj od tih potreba valja pristupiti različitom metodom na temelju podataka iz prošlosti.

Pretpostavke za primjenu stohastičkog istraživanja potreba jesu (Ferišak, 2006):

- da se vodi evidencija potrošnje i stanja zaliha materijala;
- da je broj podataka iz vremenskog niza dovoljan za eliminiranje slučajnih kolebanja;
- da se raspolaže podatcima iz kontinuiranog slijeda kretanja potrošnje u dužem razdoblju.

Heurističke metode

Koriste se za materijale malene vrijednosti za koje se ne raspolažu podatci o prošloj potrošnji npr. potrebe materijala za nove proizvode. Heurističke se metode koriste u slučajevima kada se zbog malene vrijednosti materijala ne isplati primijeniti neku od prethodno navedenih metoda ili ako se ne raspolažu podatci na temelju kojih bi se moglo primijeniti determinističko ili stohastičko istraživanje potreba.

„Često se primarne i sekundarne potrebe procjenjuju prema subjektivnim ocjenama zahtjeva tržišta i mogućnostima njihova realiziranja u poduzeću. Primarne se potrebe procjenjuju u službi prodaje. Tu može biti riječ o zahtjevima za novim proizvodima s drukčijom strukturom od postojećih, što dovodi do promjena sekundarnih potreba. Sekundarne se potrebe mijenjaju i prilikom provedbe normizacije sastavnih dijelova proizvoda.“ (Ferišak, 2006)

Heurističke metode se u pravilu koriste u istraživanju potrebe za malen broj predmeta rada. U procjeni takvih potreba najčešće se koriste logičke i intuitivne metode. Logičke metode procjene potreba temelje se na analognim potrebama iz prethodnih razdoblja. Dok su intuitivne procjene rezultat slobodne procjene pojedine osobe ili skupine djelatnika. U tu svrhu procjene koriste se različiti postupci, poput procjene ekstrema te traženje srednjih vrijednosti.

4. Poduzeće Hilding Anders d.o.o.

Temelji ove uspješne kompanije postavljeni su 1979. godine u Čehovcu pored Preloga kada su Stjepan i Marija Hrešć započeli s preradom otpadne plastike, ali uz intenzivan rast, veliku sklonost inovacijama te kontinuirano investiranje u modernizaciju proizvodnje i razvoj novih programa proizvoda bilo je neminovno preseljenje proizvodnje na lokaciju koja će osigurati i daljnja, buduća proširenja. I upravo tom je odlukom izgradnjom nove Hespo tvornice u Prelogu 1989. godine na toj lokaciji utemeljenja današnja gradska industrijska zona. Usmjerenost neprestanom razvoju proizvoda i proizvodnje rezultirala je prijavljivanjem brojnih svjetskih patenata uslijed kojih je Hespo zapazila i velika američka kompanija Legget & Platt Incorporated. U svibnju 2000. godine toj je kompaniji prodana proizvodnja opružnih jezgri i strojogradnja, a Hespo se u potpunosti koncentrira na daljnji razvoj proizvodnje madraca i namještaja te investira u nove proizvodnje pogone, tehnološku modernizaciju, povećanje proizvodnih kapaciteta i daljnje razvijanje kvalitete.

2005. godine Hespo je u potpunosti prodan i postaje članom Hilding Anders grupe koja je apsolutni lider u proizvodnji madraca i kreveta na 40 tržišta diljem Europe, Azije i Rusije. Iza ove je globalne kompanije sa sjedištem u Švedskoj, 75 godina postojanja i iskustva, a u 31 tvornici diljem Europe i Azije imaju ukupno 7 000 zaposlenih, uz godišnju proizvodnju od cca 8 mil. madraca plus svi ostali proizvodi iz bogatog programa. Ova je uspješna kompanija željela upravo Hespo iz Preloga u svojoj poslovnoj obitelji jer, na svim tržištima na kojima posluje, objedinjuje najrenomiranije i najuspješnije brandove koji su već imali dokazani status tržišnog lidera. Na taj način i Hespo je osigurao daljnji kontinuirani razvoj i ekspanziju na nova, atraktivna tržišta. I nakon promjene vlasnika proizvodnja se nastavila dalje konstantno usavršavati i modernizirati uvođenjem novih, numerički upravljanim, visokoproduktivnih strojeva te je otvorena neposredno nakon toga i nova tvornica, specijalizirana za proizvodnju navlaka za madrace pod sestrinskim nazivom Hilding Croatia.

2007. godine Hespo kupuje i drugi najjači hrvatski brand u proizvodnji madraca i kreveta PerfectaDreams i proizvodi na dvije lokacije sve do 2012. godine kad se cjelokupna proizvodnja seli u Prelog. Kompanija nastavlja poslovati pod

imenom Hespo sve do 2013. godine kad ga mijenja u Hilding Anders d.o.o. kako bi pod tim krovnim imenom paralelno dalje razvijala oba jaka branda, Hespo kroz sve značajnije veleprodajne lance i salone namještaja te Perfectu kroz vlastitu maloprodajnu mrežu.

Danas Hilding Anders grupacija u Prelogu zapošljava oko 700 djelatnika i ostvaruje godišnji prihod od cca 350 mil. kuna te posluje na ukupno 42 000 m2 proizvodne i skladišne površine, uz dodatne distributivne centre u Rijeci i Splitu radi bržih i kvalitetnijih isporuka.

Poslovna, pozitivna upornost i usmjerenost neprestanom razvoju i rastu i nadalje je karakteristika ove kompanije iz Preloga. Uslijed stalnog rasta povećavaju se i skladišni i proizvodni prostori. Stalno unapređivanje kvalitete proizvodnje te kvalitete usluga i proizvoda i dalje su prioritet i osnovni motivator u pažljivo planiranom daljem razvoju i strategiji.

Kvaliteta Hespo proizvoda međunarodno je potvrđena dobivanjem Certifikata ISO 9001 za kontrolu kvalitete proizvodnje i proizvoda 1998. godine, u čemu su bili među prvim tvrtkama u Hrvatskoj. Proširenje norme na ISO 9001:2000 izvršeno je 2002. godine.
Iako su svi Hespo proizvodi testirani i potvrđeni u institutima za ispitivanje kvalitete, posjeduju i vlastite test-mašine te konstantnim vlastitim provjerama žele osigurati zadovoljstvo korisnika svojih proizvoda.

S više od 200 000 prodanih madraca godišnje, 50 000 tapeciranih kreveta, 130 000 podnica i 90 000 komada namještaja za spavaće i dječje sobe, Hilding Anders je vodeći proizvođač madraca, podnica, kreveta i namještaja u Hrvatskog te pokriva 65 % domaćeg tržišta. Osim neospornog statusa tržišnog lidera na hrvatskom tržištu, Hilding Anders ima i značajne izvozne rezultate od 45% ukupne proizvodnje madraca, podnica i namještaja. te stalnu tendenciju rasta izvoza. Proizvodnja navlaka gotovo je u potpunosti izvozno orijentirana jer, od ukupno godišnje proizvedenih milion navlaka za madrace 90% njih se izvozi. Iza svih ovih rezultata je respektabilnih 25 godina iskustva na domaćem i inozemnim tržištima, kontinuiranog rasta i razvoja te brojnih nagrada za uspješno poslovanje, kvalitetu proizvoda i proizvodnje te inovativnosti.

Rezultat toga je neosporna uloga tržišnog lidera na regionalnom tržištu madraca te snažan brand prepoznat od strane krajnjih korisnika kao sinonim za

udobnost, kvalitetu i zdravlje. Hilding Anders u svom proizvodnom programu ima sve proizvode vezane uz kvalitetno spavanje: madrace, jastuke, poplune, elastične podloge, različite vrste drvenih i tapeciranih kreveta te namještaj za spavaće i dječje sobe. U Prelogu se nalazi 5 različitih pogona sa sljedećom godišnjom proizvodnjom : madraci – 200 tisuća komada

podnice – 130 tisuća komada

namještaj – 90 tisuća komada

tapecirani – 50 tisuća komada

navlake – milijun komada.

Sjedište tvrtke smješteno je u sjevernom dijelu Hrvatske, a dodatni distribucijski centri su: distributivni Centar Rijeka, distributivni Centar Split, 11 Perfecta Salona, 21 Happy Dreams Salona. S ovih lokacija pokrivaju regionalna tržišta Hrvatske, Slovenije, Srbije, Bosne i Hercegovine, Makedonije, Crne Gore, Bugarske i Rumunjske.

Zahvaljujući renomiranim robnim markama Hespo i Perfecta dugoročno su osigurali vodeću tržišnu poziciju. Na svim tržištima na kojima posluju u potpunosti su predani zahtjevima kupaca koji se odnose na njihov proizvodni program te se kontinuirano dalje razvijaju i povećavaju položaj tržišnog lidera. Opremanjem hotela njihovim krevetima i madracima otišli su čak i korak dalje. Njihovi planovi uključuju trajna ulaganja u lokalne regije, generiranje prihoda, stvaranje novih radnih mjesta, razvijanje infrastrukture te pružanje podrške zajednici u kojoj djeluju.

Kronološki slijed od osnivanja prve tvornice do pripajanja Hilding Anders grupi:

- 1979. otvorena mala tvornica za preradu plastike
- 1983. dizajniran i patentiran prvi stroj za preradu plastike
- 1989. pokrenuta proizvodnja Bonell & Pocketed jezgri
- 1991. početak proizvodnje madraca
- 1998. ISO 9001 Certifikat

- 2000. proizvodnja strojeva i jezgri prodana L&P (T)
- 2000. ulaganje i proizvodnja namještaja
- 2001. novi pogon za proizvodnju madraca
- 2003. novi pogon za proizvodnju namještaja
- 2005. pripajanje HILDING ANDERS-u
- 2006. proizvodnja navlaka s kapacitetom od 1 milijuna komada pokrenuta u HILDING CROATIA
- 2012. proizvodnja madraca Perfecta branda preseljena u Prelog
- 2013. Hespo, Perfecta and Happy Dreams spojeni u jedan poslovni subjekt HILDING ANDERS
- 2016. HILDING CROATIA se pripaja HILDING ANDERSU

Slika 2 Hilding Anders i Hilding Croatia - Neto prodajni rezultati

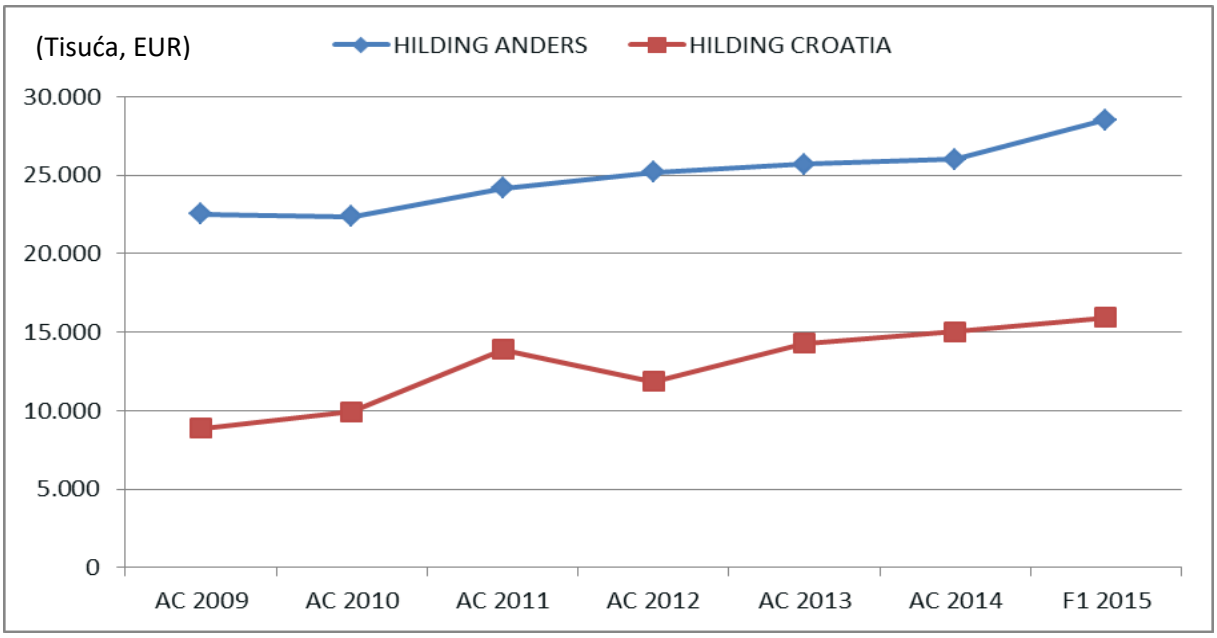

Izvor: Interni izvori tvrtke Hilding Anders

Slika 3 Neto prodajni rezultati izraženi brojčano

Net Sales k€	AC 2009	AC 2010	AC 2011	AC 2012	AC 2013	AC 2014	F1 2015
HILDING ANDERS	22.494	22.365	24.154	25.186	25.672	25.999	28.513
HILDING CROATIA	8.852	9.908	13.885	11.859	14.293	15.017	15.923
TOTAL	31.346	32.273	38.039	37.045	39.965	41.016	44.436

Izvor: Interni izvori tvrtke Hilding Anders

Iz slike 2 (grafikona) i slike 3 (tablice) možemo vidjeti da tvrtka Hilding Anders bilježi konstantan rast prodaje, dok tvrtka Hilding Croatia bilježi rast do 2011. godine. Godine 2012. bilježi lagani pad, no nakon toga tvrtka bilježi rast neto prodaje. Jedni od strateški važnijih kupaca su JYSK i Lesnina. JYSK je najveći kupac i postaje lider na tržištu zbog rasprostranjenosti i cijena. S druge strane Lesnina je kupac s 12 godina stabilne suradnje. U ostale kupce tvrtka Hilding Anders ubraja: Steinhoff - Kika/Leiner & Conforama/Emmezetta, Intermod, Harvey Norman te druge manje kupce.

MISIJA - „Naša misija je omogućiti svijetu dobar san.“

VIZIJA – „Postati vodeći proizvođač kreveta priznat u djelatnosti i pouzdan u očima kupaca.“ (Izvor: http://www.hildinganders.com/markets/croatia/hr, preuzeto:14.01.2018.)

Slika 4 Organizacijska struktura poduzeća Hilding Anders

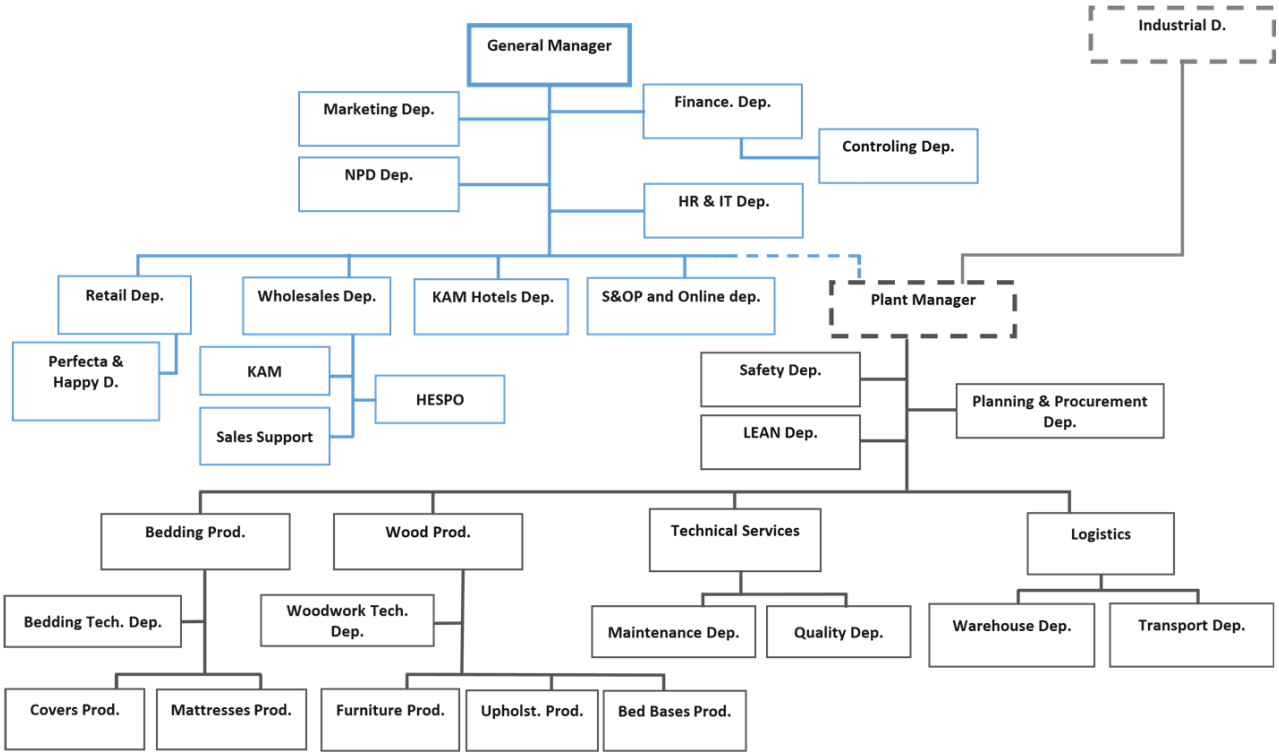

(Izvor: Interni podaci poduzeća Hilding Anders)

Organizacijska struktura poduzeća Hilding Anders d.o.o. pripada kombinaciji funkcijske i predmetne organizacijske strukture. Podjela rada, grupiranje i povezivanje poslova, kao i povezivanje organizacijskih jedinica, obavlja se prema odgovarajućim poslovnim funkcijama i svaka organizacijska jedinica obavlja poslove određene funkcije za cijelu organizaciju. Npr. poslovna jedinica Financije, Marketing, HR & IT (ljudski resursi i IT), prodaja i dr. obavljaju poslove za sve poslovne jedinice odnosno za svih 5 različitih proizvodnji. Predmetna organizacijska struktura podrazumijeva grupiranje pojedinačnih zadataka u takve organizacijske jedinice koje su usmjerene na stvaranje jedne vrste ili skupine proizvoda ili usluga, u ovom konkretnom slučaju u jednu grupu spadaju proizvodnja madraca i navlaka i u drugu grupu spadaju proizvodnja namještaja, tapeciranih kreveta i podnica. Odjel nabave djeluje zajedno s

odjelom planiranja i pod nadležnosti su Plant managera u čijoj su nadležnosti sve proizvodnje, tehnička služba (održavanje i kvaliteta), logistika, zaštita na radu i LEAN (procesna tehnologija).

Organizacijska struktura nabave u HA

Odjel nabave u HA je centraliziran za sve pogone (navlake, madrace, podnice i namještaj). Centralistički oblik organizacije nabavne službe uvjetuje niže troškove nabave, a ti niži troškovi uvjetovani su većim količinama nabavki materijala koje služba nabavlja za potrebe svih pogona. Veće količine omogućuju nabavljanje po nižim cijenama jer se za veće količine mogu dobiti rabati. Druga je prednost centralizirane nabave u tome da taj oblik ne zahtjeva velik broj nabavnog osoblja kao što je slučaj kod decentralizirane nabave. Ovakva struktura nabave omogućuje i sniženje normativa zaliha. Sljedeća prednost je u tome da omogućuje standardizaciju materijala i dobavljača. Također omogućuje specijalizaciju referenata nabave (buyer) za određene predmete nabave ili za dodijeljene im funkcije. Na taj način mogu bolje upoznati materijale koje naručuju i postići bolje rezultate u poslovanju nego da se bave mnogim predmetima. Neki pogoni koriste zajedničke materijale pa bi se tako moglo dogoditi da isti materijal kod istog dobavljača naručuju dvije različite osobe što nema smisla i povisuje troškove i zalihe materijala. Prednost ove vrste nabave je i u boljem ostvarivanju jedinstvene politike nabave, kao i u lakšoj kontroli i analizi nabavnog poslovanja i pregledu nad tržištem nabave. Dakle, *buyeri* su zaduženi za svoje kategorije odnosno svoju grupu materijala (npr. spužva, jezgre, platna, pločasti materijali, okov sl.) i oni posebno za svoje grupe materijala nabavljaju iste. Na nivou cijele grupacije postoji „lead buyer“ za glavne strateške materijale (platna, spužvu, drvo) koji dogovaraju cijene s grupnim dobavljačima za cijelu grupaciju kako bi postigli najbolje cijene.

4.1. Nabava u Hilding Andersu d.o.o.

Najjednostavnije rečeno, nabava je (izvor: Cronata, nabavna akademija u 3 modula):

- proces, funkcija, odjel -segment u organizaciji
- mjesto gdje se generiraju troškovi
- mjesto gdje treba pregovarati i snižavati cijene
- mjesto gdje se kontrolira rok isporuke od dobavljača
- mjesto gdje se rješavaju reklamacije prema dobavljačima
- mjesto gdje svi zovu kada nešto fali
- mjesto gdje dobavljači zovu kada treba platiti.

Pojam nabave može se definirati kao nabava robe/usluge odgovarajuće kvalitete iz odgovarajućih izvora odnosno pravovremena dostava na odgovarajuće mjesto uz odgovarajuću cijenu. To je proces koje se vodi unutar organizacijske jedinice koja je zadužena za dobavu zaliha roba i usluga po pravoj kvaliteti, količini i cijeni u pravo vrijeme te upravljanje dobavljačima s ciljem doprinosa konkurentskoj sposobnosti te ostvarenju ciljeva poslovne strategije.

Podjelu nabave u HA možemo podijeliti na:

- Operativnu – preuzimanje i upravljanje upitima, procesuiranje narudžbi, praćenje isporuka, ovjeravanje ulaznih računa, rješavanje reklamacija, komunikacija s dobavljačima i internim korisnicima (drugim odjelima)
- Taktičku (sourcing /savings) – planiranje, pregovaranje, ugovaranje, sastanci i posjete dobavljača, izvještavanje, praćenje ušteda, KPI
- Stratešku - uvođenje i upravljanje kategorijama materijala, uvođenje i razvoj strategije upravljanja dobavljačima, prepoznavanje i kontrola rizika, organizacijski razvoj

Planiranje nabave:

Izvor: Cronata, nabavna akademija u 3 modula

Planiranje uglavnom kreće od prodaje. Naime, prodaja mora dati prognozu očekivanih prihoda za sljedeću godinu. Naravno da ta brojka mora biti veća od prihoda ostvarenih u tekućoj godini. Takav plan prihoda najčešće se razrađuje po kupcima/tržištima i asortimanu/grupama proizvoda. Isto tako, nužno je planirati hoće li se plasirati novi proizvod, nova kategorija proizvoda, hoće li nešto od proizvoda ugasiti odnosno maknuti s tržišta i sl. Što je plan prodaje detaljniji, tada je i daljnje planiranje preciznije. U praksi se od strane prodaje često govori da je teško planirati i predvidjeti prihode u narednom periodu, no uz kombinaciju prethodnih godina, razgovora s kupcima i iskustvu, ipak se može izraditi vrlo kvalitetan i detaljan plan prodaje i prihoda za naredni period.

Plan prodaje izražava se u količini prodanih proizvoda, ali naravno i u financijskom iznosu. Tu svakako treba voditi računa i o politici prodajnih cijena – hoće li se cijene korigirati, na kojem asortimanu, u kojem iznosu, na kojim tržištima i sl. Kada govorimo o proizvodnim poduzećima, plan prodaje je osnova za razradu plana proizvodnje. Plan proizvodnje utvrđuje raspored proizvodnje po proizvodnim kapacitetima i proizvodnim linijama. Jednom kada imamo razrađeni plan proizvodnje vrlo je jednostavno doći po plana potrebnih materijala, odnosno možemo reći da je to okvir za izradu plana nabave. Ako se poduzeće bavi proizvodnjom, tada se iz plana prodaje u pravilu generira plan nabave. Planiranje nabave je proces koji najjednostavnije podrazumijeva što će kupiti, kada i od koga. Osnovna zadaća planiranja nabave je da zadovolji potrebe koje tvrtka ima u smislu materijala, roba i usluga nužnih za obavljanje osnovne djelatnosti. Zašto je planiranje nabave važno? Prije svega jer daje poduzeću jasnu sliku što treba nabaviti, u kojoj količini i uz koje troškove. Ujedno pomaže da determinira jesu li očekivanja realistična; primarno se tu misli na očekivanja one strane koja očekuje da se nabava realizira u kratkom roku, a ne u skladu s regularnim metodama i rokovima nabave. Planiranje nabave predstavlja i priliku da svi korisnici usluga nabave (krajnji korisnici, proizvodnja, tehnički odjel, dobavljači) daju svoje relevantne inpute vezane uz pojedine specifične zahtjeve.

Prilikom planiranja nabave dobiva se mogućnost kreiranja strategija za nabavne kategorije koje su uključene u plan. Kvalitetno planiranje nabave bitno je radi optimizacije procesa nabave u cilju ostvarivanja ciljeva tvrtke. Prije svega pruža transparentnost, omogućuje efektivno i pravovremeno prikupljanje ponuda te

proaktivno sprječava potencijalna kašnjenja u dobavi. Kroz planiranje omogućeno je bolje upravljanje dobavljačima, pronalaženje pravog dobavljača za svaku kategoriju, a grupiranjem materijala i količina postižu se bolji uvjeti i kvalitetnija suradnja s dobavljačima. Prilikom planiranja nabave važno je uzeti u obzir i stanje materijala i robe koja se nalazi na skladištu, ako ono postoji. Vrlo se često zaboravi da na skladištu poduzeće ima neko početno stanje koje je također dovoljno da se zadovolje potrebe tvrtke u određenom periodu. Iz svih tih razloga važno je planiranju posvetiti dovoljno vremena, koristiti što više informacija i podataka, kako internih, tako i iz okruženja, a s ciljem da planovi budu što egzaktniji i služe kao kvalitetan alat u ostvarivanju zadanih ciljeva tvrtke.

(Izvor: http://www.jatrgovac.com/2018/02/strategija-poslovanja-planiranje-nabave/, preuzeto: 15.01.2018.)

Upravljanje zalihama vrlo je bitno. U tu svrhu koriste se sigurnosne, signalne i maksimalne zalihe. Sigurnosna zaliha služi za pokrivanje potreba samo u slučajevima kada dođe do veće potrošnje nego što je planirano, u slučajevima kašnjenja isporuka, isporuka na krivom mjestu ili isporuka pogrešnog materijala ili ako je zbog gubitka i krađa stvarna zaliha manja nego što pokazuju podaci u evidenciji.

Signalna zaliha upozorava kada započeti nabavu kako bi poduzeće pravodobno nadopunilo zalihu, da ne mora koristiti sigurnosnu zalihu ako ne nastupe neki od mogućih rizika. Da bi se na vrijeme naručivala roba mora imati točne informacije o potrošnji artikala u planskom razdoblju te o rokovima isporuke dobavljača za artikle koji se kontinuirano troše.

Maksimalna zaliha je gornja granica zalihe, ekonomski opravdana s obzirom na troškove skladištenja i zalihe te stupanj sigurnosti zadovoljenja potreba.

Koeficijent obrtaja zaliha je pokazatelj uspješnosti poslovanja. Koliko puta su se prosječne zalihe prodale tijekom vremenskog perioda, a mjeri se kao omjer godišnjeg prometa i prosječne godišnje zalihe. Što je koeficijent obrtaja veći, to je poslovanje učinkovitije.

4.2. Prognoziranje nabave u HA

S obzirom da Hilding Anders ima 5 različitih proizvodnji koje imaju ukupno oko 10000 različitih gotovih proizvoda i za koje je potrebno nabavljati cca 5000 različitih materijala, praćenje poslovnog procesa ne bi bilo moguće bez podrške informacijskog sustava. Cilj informacijskog sustava je pribaviti informacije potrebne pri izvođenju poslovnog procesa i upravljanju poslovnim sustavom.

Poslovanje poduzeća Hilding Anders je vrlo složeno i kompleksno te stoga informacijski sustav mora biti prilagodljiv i usmjeren prema ostvarivanju zacrtanih ciljeva. Informacijski sustav je temelj za poboljšanje poslovanja te povećanje učinkovitosti. Poslovanje koje se temelji na suvremenoj informacijsko komunikacijskoj tehnologiji doprinosi bržem i kvalitetnijem razvoju poduzeća. S obzirom na složenost poslovanja i na potrebu za pravovremenim informacijama u cilju stvaranja pretpostavki za kvalitetnije upravljanje poslovnim i proizvodnim procesima donesena je odluka o potrebi implementacije informacijskog sustava koji koristi većina poduzeća u grupaciji. Tako je Hilding Anders 1.1.2016. uveo novi informacijski sustav Movex koji omogućava da su u svakom trenutku dostupne sve informacije iz svih poduzeća kojima je također Movex informacijski sustav jer koriste istu bazu podataka.

Integrirani informacijski sustav MOVEX obuhvaća sljedeće podsustave:

- prodaja i otprema proizvoda,
- nabavu i skladištenje materijala, opreme i rezervnih dijelova,
- projektiranje, konstruiranje i definiranje novog proizvoda, normativa materijala, tehnologije i normativa za izradu proizvoda,
- planiranje i praćenje pripreme proizvodnje i proizvodnje,
- skladištenje i izdavanje proizvoda s visoko-regalnog skladišta,
- planiranje proizvodnih kapaciteta,
- računalna podrška funkciji menadžmenta (kontroling),
- računovodstveni poslovi.

S obzirom da planiranje kreće s planom prodaje, kreće se od gotovih proizvoda. Hilding Anders proizvodi gotovo 10000 različitih gotovih proizvoda, od toga 2000

različitih madraca, 500 podnica, 1000 tapeciranih kreveta, 3500 različitog komadnog namještaja i 3000 navlaka. Za proizvodnju tako opsežnog programa potreban je i jako velik broj različitih materijala cca 5000. Za sve to je bilo potrebno dobro razviti sustav šifriranja i grupiranja kako gotovih proizvoda tako i materijala. I za gotove proizvode i za materijale postoji jedinstven sustav šifriranja

- item, npr. R1000360006 FO BL PU2337 RED 161020301200
- item tip, npr. 100 FOAM
- item grupa, npr. 10000036 FO BL PU23

Svaki proizvod ili materijal ima svoju šifru i pripada određenom item tipu i još niže item grupi. Sve to je neophodno radi lakšeg pretraživanja i izvještavanja. Svaka šifra mora imati kratki naziv, dugi naziv, određenu jedinicu mjere, dimenzije, itd. U bazu podataka sustava također se unose različiti parametri kao što je minimalna količina za proizvodnju, multiple količina, sigurnosna zaliha, potrebno vrijeme izrade itd.

Svaki gotov proizvod mora imati sastavnicu sa svim materijalima iz kojih se proizvode te operacije. Sastavnica sadrži šifru i naziv proizvoda ili sklopa na koji se odnosi, podatke o komponentama (sastavnim dijelovima i materijalima) od kojih se sastoji proizvod i o količinama potrebnih komponenata, izraženih u jedinicama mjere u kojima se zaprima i vodi na skladištu (npr. u komadima, kilogramima, metrima, setovima itd.). Na temelju sastavnica, u kojima su analitički prikazane komponente proizvoda, može se napraviti pregled potrebnih materijala, dijelova i sklopova u pojedinim proizvodima, kreira se potreba za materijalima i služe za izradu kalkulacija. Ukupne potrebe za materijalima u planskom razdoblju dobiju se množenjem potrebnih materijala za određene proizvode s potrebama tih proizvoda. Pravovremeno zadovoljavanje potreba ovisi i o vremenu nabavljanja pojedinih materijala kao i o vremenu protoka materijala u proizvodnom procesu i zbog toga je u sustavu. Kod kreiranja potreba za nabavu u sustavu, uzimaju se u obzir svi parametri koji su definirani u sustavu i na osnovu prognoziranja (forecasta) prodaje.

Uspješno upravljanje nabavom zahtijeva prognozu budućih događaja. Mnogi profesionalci još uvijek planiraju na temelju intuicije, a drugi pak se oslanjaju samo na logično rasuđivanje. Nekad to daje odlične rezultate, nekad baš i ne. Rizik i nesigurnost se nalaze u temeljima planiranja. Proces ‘forecastinga’ je vještina procjene u

nepoznatim situacijama – od same prognoze važnija je vještina izrade scenarija za slučajeve da se plan ostvari, ali i za slučaj da se ne ostvari. General Eisenhower je rekao: '…u pripremama bitaka, shvatio sam da su planovi beskorisni, ali da je planiranje nezamjenljivo'. (Izvor:https://lider.media/znanja/forecasting-vjestina-za-uspjesno-vodenje-nabave/, preuzeto: 15.01.2018.)

Svaki program u lancu opskrbe počinje nekim planom, a plan je u stvari prognoziranje. Kao što kaže citat, važniji je sam proces planiranja nego sam plan jer smo svjesni toga da je plan u ovoj ili onoj mjeri pogrešan. Međutim, kroz proces planiranja mi moramo komunicirati s kolegama iz ostalih odjela, s poslovnim partnerima i promatrati statističke podatke, a to je ono što je najvažnije. U procesu planiranja koriste se razne tehnike i metode, ali u stvari dvije su osnovne metode prognoza: kvalitativne i kvantitativne. Za većinu se poduzeća isplati primijeniti kombinaciju matematičkih analiza povijesnih podataka (analiza pomoću kvantitativnih tehnika) s kvalitativnom analizom (izrada scenarija, stručna mišljenja i fokus grupe) prognoza.
(Izvor:http://www.progressive.com.hr/component/content/article/62-kolumne/1445-forecasting-poslovno-planiranje-.html, preuzeto: 15.01.2018)

S kvalitativnim metodama treba biti oprezan jer se kvalitativne metode temelje na intuiciji i subjektivnoj procjeni. Matematičke tehnike prognoza temelje se na povijesnim podacima odnosno na prošlim događajima. Teorija koja stoji iza ovih metoda polazi od pretpostavke da povijesni podaci u većoj ili manjoj mjeri utječu na događaje u budućnosti. Međutim, iako stara latinska poslovica kaže da je 'Povijest učiteljica života', iskustvo nam govori da se niti povijest ne ponavlja baš uvijek, a i neke artikle i događaje je lakše predvidjeti, dok je druge teže. (Izvor: https://lider.media/znanja/forecasting-vjestina-za-uspjesno-vodenje-nabave/, preuzeto: 15.01.2018.)

Poduzeće Hilding Anders prognozira buduću prodaju kombinacijom kvantitativnih i kvalitativnih podataka. Prognoziranje (forecast) prodaje se radi na sljedeći način:

1. Za forcastiranje koriste alat koji se zove *S&OP – Sales and Operatinal Planning*. Baza su excel tablice koje uzimaju u obzir povijesnu prodaju i na temelju

indexa sezonalnosti i povijesti predlažu prognozu (forecast) za četiri mjeseca unaprijed. Dakle za standardne proizvode predviđanje se radi u Excelu pomoću formule: prošlogodišnja količina prodaje u određenom periodu pomnožena s koeficijentom rasta/pada (usporedba količine tri zadnja mjeseca tekuće godine s količinama iz istoga perioda prethodne godine). Prognoza (forecast) s prodajne strane pomoću tog alata revidira se na više razina:

- glavnoj razini GM – glavni direktor odlučuje je li prognozirana prodaja (vrijednosno) u redu i u skladu s definiranim budžetom. Vrijednost se može smanjiti ili povećati i automatski se to rasporedi na niže razine.
- po lancima kupaca (bussines chain) / kupcima. Ako se u toj razini vidi da neki lanac kupaca (npr. XXXL Lutz) ili kupac ima previsok ili prenizak iznos može se promijeniti, ukupno na sve proizvode jednako ili
- na grupu proizvoda (npr. madrac Exclusiv). Ako se zna da se planira akcija za naredne mjesece, očekuje se veća prodaja. Vrijednost prodaje se može promijeniti, koja se dalje raspoređuje na gotove proizvode po dimenzijama.

Dalje odjel planiranja provjerava količine i provjerava je li moguće to proizvesti (jesu li mogući kapaciteti i dostupni materijali).

2. Neki kupci šalju svoj forecast (npr. Jysk) kojega onda netko iz prodaje prekontrolira i unese u sustav, dok se ostali kupci prognoziraju (forcastiraju) prema inputima prodajnih predstavnika i prema definiranom budžetu.

3. Za potpuno nove proizvode prodaja određuje procijenjene količine prodaje po artiklu na temelju istraživanja tržišta i informacija od kupaca.

Kada se odluči da je plan prodaje koji je revidiran S&OP alatom u redu, on se transportira u MRP (Movex). Hilding Anders ima i intercompany prodaju (tvornice iz grupacije Hilding Andersa). Njihov se forecast preslikava u forecast Hilding Andersa Prelog i nije ga potrebno posebno unositi u sustav.

Kako postoji baza podataka za gotove proizvode tako postoji baza podataka i za materijale. U bazu podataka se unose parametri na temelju kojih će se generirati prijedlozi potrebe za nabavom (planirane narudžbe). Dakle, svaki materijal mora imati svoju šifru, potrebno je definirati osnovnu jedinicu mjere, odrediti glavnog dobavljača, rok isporuke kod glavnog dobavljača, broj dana za koji se materijal naručuje (npr. potreba za 5 dana ili ako se materijal naručuje jednom mjesečno onda je to 20 radnih

dana i sl.), minimalna količina za narudžbu, multiple faktor (npr. jezgra ima pakiranje od 40 kom i muliple faktor je tada 40 što znači da se ne može naručiti npr. 50 kom, već 40, 80,120 itd.), sigurnosna zaliha, planer/buyer – osoba koja je zadužena za nabavu materijala, za koji pogon se naručuje materijal, itd. Cjenik dobavljača i uvjeti kod dobavljača: paritet, valuta plaćanja i sl. se također unose u sustav jer su ti podaci potrebni i koriste se prilikom kreiranja narudžbi. Sustav automatski vuče sve te podatke iz baze podataka. Osim što su ti podatci potrebni za kreiranje narudžbi, potrebni su i knjigovodstvu jer olakšavaju knjiženje ulaznih računa za materijal s obzirom da su cijene i svi uvjeti dobavljača u sustavu. Prilikom zaprimanja materijala na skladištu, materijal odmah dobiva vrijednost i kod knjiženja ulaznih računa primka se povezuje s računom.

Na temelju planiranja prodaje (forecasta), stvarnih narudžbi pristiglih od kupaca, planiranih radnih naloga za proizvodnju i svih parametara koji u sustavu postoje, kreira se potreba za materijalom odnosno prijedlogom narudžbe za dobavljača. Svaki planer/buyer (osoba u nabavi zadužena za određenu grupu materijala i određenog dobavljača) svakodnevno vidi u sustavu sve potrebe za materijalima koje treba naručiti. Da se ne mora svaki dan pregledavati svaki pojedini materijal i dobavljač, jer bi to bilo nemoguće, postoje načini koji to olakšavaju. Sustav signalizira s različitim porukama koje treba pratiti, npr.

A1 – već kasnimo s narudžbom odnosno potreba je prije dogovorenog roka isporuke

A2 – vrijeme za narudžbu

C1 – kasni isporuka

B1 – treba ubrzati isporuku

B3 – treba prolongirati isporuku

B7 – treba stornirati isporuku.

Planer tako može birati više načina po kojima će naručivati materijal. Svaki materijal za koji je optimalno vrijeme naručivanja sustav signalizira porukama A2, a materijal koji treba proizvodnji u kraćem roku nego je rok isporuke kod dobavljača, s porukom A1. Osim informacijskog sustava Movex, planerima su dostupni i drugi alati koji olakšavaju praćenje isporuka i planiranje novih narudžbi. Jedan od takvih alata je

i LOMIS. Svi podaci iz Movex-a su ažurirani u Lomis-u koji služi samo za različite izvještaje kao npr. izvještaj za otvorene i planirane narudžbe sa uključenim stanjem na skladištu, rokom isporuke, sigurnosnom zalihom, minimalnom količinom za narudžbu, potrošnjom u određenom vremenskom razdoblju, porukama koje su već spomenute i sl.

Nakon što planer/buyer vidi prijedlog za narudžbu, još jednom povjeri potrebu u materijal planu, usporedi s prošlom potrošnjom, po potrebi se konzultira s ostalim odjelima i tek kad se uvjeri da je potreba stvarna i realna, ide u kreiranje narudžbe i slanje dobavljaču. Većina dobavljača šalje natrag potvrdu narudžbe i te se potvrde unose u sustav. Dobavljač može potvrditi i kasniji datum od traženog ili potvrditi drugačiju količinu od zahtijevane i to se mora također unijeti u sustav, promijeniti datum isporuke ili količina. To je vrlo važno jer na temelju potvrđenih narudžbi planer proizvodnje planira radne naloge za proizvodnju.

Svako odstupanje od planiranog, bilo da je to promjena datuma izrade u proizvodnji ili promjena količine za proizvodnju u odnosu na prijedlog, stvara probleme u nabavi. Nabavlja se materijal koji je nepotreban, mora stajati na skladištu i čekati, zauzima mjesta na skladištu i mora se platiti prije nego li je to potrebno i obrnuto. Ako materijal nije isporučen na datum u sustavu ili su količine manje, to pak stvara probleme u proizvodnji. Ne može se lansirati nalog u proizvodnju ako nedostaje samo i jedna komponenta.

Na kraju svakog mjeseca radi se analiza planirano/proizvedeno/isporučeno. Rade se KPI tablice kojima se svaki mjesec provjerava točnost planiranja (forecasta) i na kojim lancima (business chain), kupcima i grupama proizvoda je najveće odstupanje. Kao što je već spomenuto, planiranje (forecastiranje) je veoma težak i zahtjevan posao i često se događaju velika odstupanja od planiranog.

Tablica 1 prikazuje prilagođenu KPI tablicu za 2017. godinu iz koje se vidi praćenje forecasta, prodane količine, proizvedene količine, stope promjene prodane količine u odnosu na forecast – St1, te stopu promjene prodane količine u odnosu na prodanu količinu u 2016. godinu – St2. Iz priložene tablice možemo zaključiti da je uglavnom u 2017. godini za Jysk forecast bio veći od prodane količine osim jednog mjeseca (9. mjesec). Dok je prodaja u odnosu na 2016. godinu bila manja u šest mjeseci i veća u šest mjeseci i to pretežito u drugoj polovici godine. Za madrace je

ukupno također forecast u cijeloj godini bio veći od prodane količine, ali u odnosu na 2016. godinu prodano je više u 9 mjeseca, a manja prodaja je bila samo u 3 mjeseca.

Tablica 1 Analiza forcasta, prodane i proizvedene količine madraca za Jysk i madraca ukupno

2017	JYSK						MADRACI UKUPNO					
mjesec	forecast	prodano	proizvedeno	S_t1	2016	S_t2	forecast	prodano	proizvedeno	S_t1	2016	S_t2
1	7.492	3.917	4.268	-48%	4.264	-8%	12.455	7.899	9.063	-37%	7.260	9%
2	4.529	2.376	1.965	-48%	2.900	-18%	13.055	9.310	8.558	-29%	9.376	-1%
3	5.447	3.583	3.153	-34%	2.900	24%	16.081	12.273	12.637	-24%	9.430	30%
4	3.832	3.474	2.675	-9%	3.513	-1%	14.892	11.856	11.827	-20%	10.788	10%
5	3.242	3.212	3.651	-1%	3.648	-12%	12.265	11.409	11.968	-7%	11.751	-3%
6	5.069	5.059	4.909	0%	5.577	-9%	15.387	15.365	14.761	0%	13.304	15%
7	5.592	5.142	4.647	-8%	5.367	-4%	13.208	12.449	11.849	-6%	11.252	11%
8	6.764	6.041	5.329	-11%	4.902	23%	16.323	13.112	12.333	-20%	12.602	4%
9	5.060	5.565	5.782	10%	5.338	4%	13.081	12.310	12.872	-6%	13.164	-6%
10	6.846	6.164	7.176	-10%	4.494	37%	14.816	12.937	14.027	-13%	11.586	12%
11	9.742	8.656	10.184	-11%	5.429	59%	18.282	15.991	17.584	-13%	11.118	44%
12	6.413	6.187	4.616	-4%	5.526	12%	14.229	12.096	9.443	-15%	9.990	21%

Izvor: obrada autora prema podacima firme Hilding Anders d.o.o.

5. Trend analiza nabave u Hilding Andersu

Dugoročna tendencija razvoja pojave u vremenu opisuje se modelima trenda. Ako se promatrane pojave mijenjaju za približno jednake iznose, odnosno postoji neka pravilnost u promjenama vrijednosti, njezino kretanje možemo opisati linearnim trendom.

5.1. Prognoza potreba materijala za proizvodnju madraca modelom linearnog trenda

U ovom radu, na primjeru potrošnje nekoliko materijala za proizvodnju madraca za 2017. i prvih 7 tjedana u 2018. godini, prema podacima u Prilogu 1, primjenom jednostavnog linearnog trenda prognozira se potreba za naredna 4 tjedna.

Vrijednosti dobivene linearnim trendom uspoređuju se sa vrijednostima koje su kreirane po sustavu Hilding Andersa i treća vrijednost je stvarno utrošeni materijal. Jednadžba linearnog trenda i odgovarajući parametri isti su kao i kod modela jednostavne linearne regresije. Pa jednadžba glasi:

$\hat{Y} = bx + a$

Gdje je:

X – nezavisna varijabla – vrijeme

$\hat{Y}$-zavisna varijabla – potrošnja

b – prosječno povećanje (smanjenje) varijable Y u jedinici vremena

a – očekivana vrijednost (trend-vrijednost) varijable Y ako je X_t=0 (u ishodištu vremenskog razdoblja

Zadatak je ocijeniti model linearnog trenda s ishodištem na početku vremenskog razdoblja i njegovu reprezentativnost te izračunati trend vrijednosti. Podaci koji će se koristi dobiveni su u poduzeću Hildning Anders, a prikazani su u Prilogu 1 na kraju rada. Na temelju tih podataka pomoću MS Excela za svaki pojedini materijal prikazani su linijski grafikoni i jednadžba linearnog trenda, na temelju koje se izračunavaju vrijednosti za naredna 4 tjedna. Promatrana su 4 materijala i to:

1. R110036006 SPUŽVA BLOK PU2337 RED 161020301200
2. R100360007 SPUŽVA BLOK PU2337 RED 181020301200
3. R1020820018 ŽIČANA JEZGRA PO 5Z 1.65/1.8 0F 078018600125
4. R1020820021 ŽIČANA JEZGRA PO 5Z 1.65/1.8 0F 149018600125

Slika 5 Potrošnja za R110036006 SPUŽVA BLOK PU2337 RED 161020301200 u komadima

Izvor: Rezultat obrade MS Excel programa

Jednadžba linearnog trenda za ovaj model glasi:

$y = 0{,}1068x + 4{,}3437$

$R^2 = 0{,}137$

Y u jednadžbi označava zavisnu varijablu potrošnje materijala u komadima. Prema jednadžbi očekivana trend vrijednost u ishodišnom tjednu, 1. tjedan 2017, iznosi 4 komada (a=4,24). Potrošnja se u promatranom razdoblju svaki tjedan u prosjeku povećavala za 0,1 kom (b=0,1068). Iz jednadžbe je vidljivo da R^2 iznosi 0,137 što pokazuje da je 13,7% varijacije potrošnje objašnjeno vremenskim trendom.

U nastavku su prikazani linijski grafikoni za još 3 različita materijala i dobiveni su slični podaci.

Slika 6 Potrošnja materijala R100360007 SPUŽVA BLOK PU2337 RED 181020301200 u komadima

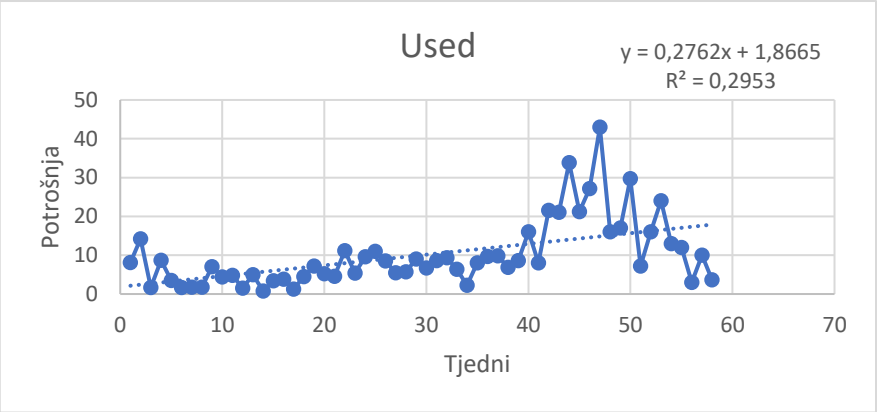

Izvor: Rezultat obrade MS Excel programa

Jednadžba linearnog trenda za ovaj model glasi:

$y = 0{,}2762\ x + 1{,}8665$

$R^2 = 0{,}2953$

Y u jednadžbi označava zavisnu varijablu potrošnje materijala u komadima. Prema jednadžbi očekivana trend vrijednost u ishodišnom tjednu, 1. tjedan 2017, iznosi 2 komada (a=1,866). Potrošnja se u promatranom razdoblju svaki tjedan u prosjeku povećavala za 0,3 kom (b=0,276). Iz jednadžbe je vidljivo da R^2 iznosi 0,2953 što pokazuje da je 29,53% varijacije potrošnje objašnjeno vremenskim trendom.

Slika 7 Potrošnja materijala R1020820018 ŽIČANA JEZGRA PO 5Z 1.65/1.8 0F 078018600125 u komadima

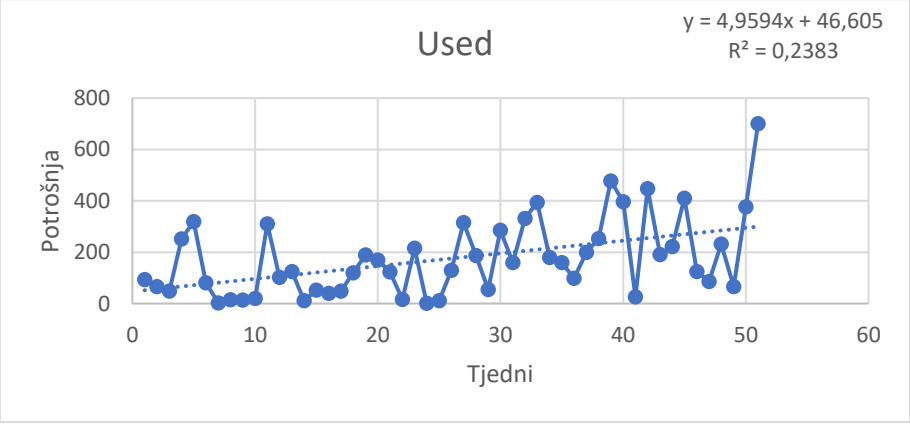

Izvor: Rezultat obrade MS Excel programa

Jednadžba linearnog trenda za ovaj model glasi:

$y = 4{,}9594x + 46{,}605$

$R^2 = 0{,}2383$

Y u jednadžbi označava zavisnu varijablu potrošnje materijala u komadima. Prema jednadžbi, očekivana trend vrijednost u ishodišnom tjednu, 1. tjedan 2017, iznosi 47 komada (a=46,6). Potrošnja se u promatranom razdoblju svaki tjedan u prosjeku povećavala za 5 kom (b=4,959). Iz jednadžbe je vidljivo da R^2 iznosi 0,2383 što pokazuje da je 23,83% varijacije potrošnje objašnjeno vremenskim trendom.

Slika 8 Potrošnja materijala R1020820021 ŽIČANA JEZGRA PO 5Z 1.65/1.8 0F 149018600125 u komadima

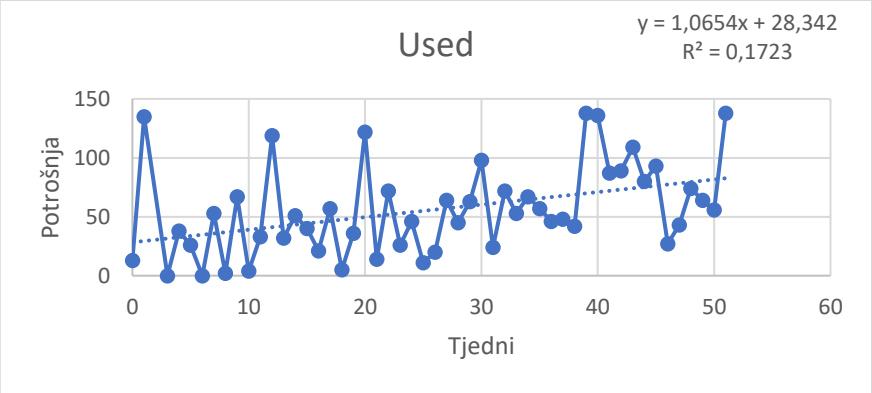

Izvor: Rezultat obrade MS Excel programa

Jednadžba linearnog trenda za ovaj model glasi:

$y = 1{,}0654x + 28{,}342$

$R^2 = 0{,}1723$

Y u jednadžbi označava zavisnu varijablu potrošnje materijala u komadima. Prema jednadžbi očekivana trend vrijednost u ishodišnom tjednu, 1. tjedan 2017, iznosi 28 komada (a=28,342). Potrošnja se u promatranom razdoblju svaki tjedan u prosjeku povećavala za 1 kom (b=1,065). Iz jednadžbe je vidljivo da R^2 iznosi 0,1723 što pokazuje da je 17,23% varijacije potrošnje objašnjeno vremenskim trendom.

U svim primjerima koeficijent deterimacije R^2 je ispod 0,30 što ukazuje da je ispod 30% varijacija potrošnje objašnjeno vremenskim trendom što ukazuje da model nije reprezentativan.

5.2. Komparativna analiza prognoziranja nabave

Na temelju jednadžbi linearnog trenda dobivenih u prethodnom dijelu izračunate su planirane potrebe za materijalima za razdoblje od 11 do 12 tjedna 2018. godine. U tabeli 2 su prikazani rezultati linearnog trenda te podaci dobiveni u poduzeću Hilding Anders za stvarnu potrošnju i planirane narudžbe prema sustavu poduzeća. Iz priložene tabele vidljivo je da su odstupanja velika. Gotovo u svim tjednima i za sve materijale je stvarna potrošnja manja od planirane po sustavu osim za dva materijala u 10. tjednu i to za R1100360007 Spužva blok PU2337 RED 181020301200 i R1020820021 Žičana jezgra PO 5Z 1.65/1.8 0F 149018600125ž . To je posljedica toga što je u prethodnom tjednu za oba materijala bilo veliko odstupanje potrošnje u odnosu na planirano, ali suprotno. Planirano je bilo puno više nego potrošeno i vjerojatno se povećala zaliha koja se trošila u 11. tjednu i nije bilo potrebe za dopremom nove količine. Količine koje su dobivene metodom linearnog trenda su približno jednake za svaki tjedan i u blagom porastu i za ni jedan tjedan ni približno ne odgovaraju stvarnoj potrošnji materijala.

*Tablica 2 Potrošnja materijala za razdoblje 1808-1812**

		R110036006 SPUŽVA BLOK			R1100360007 SPUŽVA BLOK			R1020820018 ŽIČANA JEZGRA			R1020820021 ŽIČANA JEZGRA		
Tjedni	x_t	Used	planirano prema sustavu	stvarna potrošnja	Used	planirano prema sustavu	stvarna potrošnja	Used	planirano prema sustavu	Stvarna potrošnja	Used	planirano prema sustavu	stvarna potrošnja
1808	59	10,64592	7	0	18,16278	8	1,2	339,2081	200	122	91,58326	120	23
1809	60	10,75273	11	7	18,43898	24	8	344,1675	480	120	92,66154	120	61
1810	61	10,85955	7	3,8	18,71519	2	2,8	349,1268	280	82	93,73982	40	49
1811	62	10,96637	2	1,55	18,9914	4	3,2	354,0862	200	87	94,8181	120	46
1812	63	11,07318	7	5,28	19,26761	12	7,9	359,0456	160	138	95,89638	120	74

Izvor: izrada autora prema podacima poduzeća Hilding Anders

*Razdoblje od 8. tjedna 2018 do 12. tjedna 2018. godine

Praćenjem stvarne potrošnje za određeno vremensko razdolje i analizom razlike vijednosti dobivenih linearnim trendom, zaključuje se da metoda linearnog trenda ne zadovoljava za prognoziranje potreba naručivanja materijala i predlaže se istražiti nove modele koji bi bili precizniji. Iz navedenog je vidljivo da se potrebe materijala ne mogu samo prognozirati jednom metodom (na temelju prošlih podataka) u ovom primjeru linearnim trendom i ne mogu se samo kreirati narudžbe što sustav predlaže već veliku ulogu ima i buyer/planer koji mora i sam procijeniti koliko je predložena količina za nabavu realna, svakodnevno provjeravati stanje i poruke koje sustav signalizira (treba li ubrzati isporuku, prolongirati ili nešto hitno naručiti ako se javi iznenadna narudžba kupca koja se želi isporučiti), komunicirati s ostalim odjelima, prvenstveno planerima proizvodnje da bi se provjerile i utvrdile stvarne i realne potrebe te imati snažne partnerske odnose s dobavljačima koji mogu ispuniti zahtjeve u vezi s isporukom repromaterijala, bilo prijevremeno ili u slučaju da treba odgoditi isporuku za neko vrijeme.

6. Zaključak

Jedna od osnovnih karakteristika poslovnog okruženja današnjice su brze i brojne promjene među kojima je i velika količina podataka s kojima se poduzeće svakodnevno susreće. U uvjetima rizika i neizvjesnosti u procesu planiranja i odlučivanja, u procesu poslovanja statističke metode imaju veliko značenje. Ako su podaci prikupljeni planski, smatraju se statističkim te je njihovo pretvaranje u informacije moguće upotrebom statističkih metoda. Statističke metode upotrebljavaju se u svim sferama poslovanja: razvoju, nabavi, proizvodnji, marketingu, financijama, računovodstvu i reviziji i dr. Jedna od statističkih metoda je i prognoziranje. Prognoziranje se može definirati kao predviđanje budućih događaja koje se zasniva na objektivnim i provjerenim činjenicama uz pomoć provjerenih znanstvenih metoda. U procesu planiranja koriste se razne tehnike i metode, ali su dvije osnovne metode prognoza: kvalitativne i kvantitativne. Cilj svakog poduzeća je da prognoze budu što točnije pa je za poduzeća najbolje primijeniti kombinaciju matematičkih analiza povijesnih podataka s kvalitativnom analizom prognoza. Uspješno upravljanje nabavom zahtijeva što točniju prognozu budućih događaja jer kvalitetno upravljanje procesima nabave omogućava nesmetano odvijanje proizvodnje, a donosi i brojne uštede koje osiguravaju povećanje profita.

Statističke metode: trend, korelacija i regresija primjenjuju se u mnogim stručnim i znanstvenim područjima te predstavljaju pojednostavljenu sliku stvarnih pojava. U praksi se koriste za utvrđivanje povezanosti između pojava te za predviđanje istih u budućnosti. U sklopu ovoga diplomskog rada metodom linearnog trenda prognozirane su potrebe materijala i uspoređene sa stvarnim potrošnjama kao i usporedba s podacima prijedloga narudžbe prema sustavu poduzeća te su rezultati pokazali da ta metoda nije pouzdana za prognozu potreba u nabavi. Zaključuje se da zbog velikih odstupanja treba istražiti druge metode. Ukazuje se i na veliku ulogu planera/bayera koji sam procjenjuje ili se dodatno konzultira s ostalim službama (proizvodnjom, prodajom) je li potreba generirana prema sustavu i realna te odlučuje o tome što će, za kada i koliko naručiti.

Ukoliko su odstupanja planiranih u odnosu na stvarne narudžbe kupaca velika, do izražaja dolazi pouzdan dobavljač. Iznimno je važno i potrebno imati kvalitetne i čvrste partnerske odnose s dobavljačima sirovina/repromaterijala jer upravo oni predstavljaju produženu ruku proizvodnje, o njima ovisi hoće li proizvodnja moći pozitivno odgovoriti na zahtjev krajnjeg kupca i ispuniti njihova očekivanja s odgovarajućom kvalitetom i u vremenski očekivanom terminu u kojem je taj proizvod kupcu potreban.

U Varaždinu, 29. ožujka 2018. Tatjana Grabant

Prilog 1. Potrošnja materijala za razdoblje 1701-1812*

		R110036006 SPUŽVA BLOK			R1100360007 SPUŽVA BLOK			R1020820018 ŽIČANA JEZGRA			R1020820021 ŽIČANA JEZGRA		
Tjedni	x_t	Used	Prognoza 1807-1812	stvarna potrošnja	Used	Prognoza 1807-1812	stvarna potrošnja	Used	Prognoza 1807-1812	Stvarna potrošnja	Used	Prognoza 1807-1812	stvarna potrošnja
1701	1	2,93			8,1			94			13		
1702	2	14,82			14,2			66			135		
1703	3	7,95			1,68			48			0		
1704	4	9			8,7			252			38		
1705	5	1,87			3,47			319			26		
1706	6	2,9			1,69			81			0		
1707	7	1,28			1,77			2			53		
1708	8	1,85			1,73			15			2		
1709	9	2,39			7,04			14			67		
1710	10	2,56			4,39			20			4		
1711	11	8,5			4,85			311			33		
1712	12	5,35			1,53			102			119		
1713	13	3,3			5			125			32		
1714	14	6,56			0,78			11			51		
1715	15	4,11			3,42			52			40		
1716	16	1,25			3,8			40			21		
1717	17	3,08			1,27			48			57		
1718	18	3			4,53			120			5		
1719	19	8			7,2			190			36		
1720	20	6,91			5,22			170			122		
1721	21	5,29			4,6			123			14		
1722	22	11,3			11,18			16			72		
1723	23	6,5			5,39			216			26		
1724	24	11,35			9,6			1			46		
1725	25	8,35			11,01			11			11		
1726	26	12,3			8,5			130			20		
1727	27	7,1			5,5			315			64		
1728	28	4,87			5,69			187			45		
1729	29	8,33			9,01			55			63		
1730	30	5,7			6,7			286			98		
1731	31	5			8,6			159			24		
1732	32	5,95			9,37			332			72		
1733	33	5,85			6,38			394			53		
1734	34	5,37			2,25			179			67		
1735	35	4,1			8			159			57		
1736	36	8,73			9,7			99			46		
1737	37	4			9,82			200			48		
1738	38	5			6,88			253			42		
1739	39	5,89			8,6			478			138		
1740	40	9,53			16			397			136		
1741	41	26,11			8			26			87		
1742	42	16,47			21,6			448			89		
1743	43	4			21,1			191			109		
1744	44	12,15			33,87			222			80		
1745	45	7,85			21,25			410			93		
1746	46	10			27,18			125			27		
1747	47	18			43			86			43		
1748	48	8,74			16			232			74		
1749	49	16			17			66			64		
1750	50	15,76			29,75			376			56		
1751	51	5,5			7,25			701			138		
1801	52	15,8			16			304,4925		96	84,03529		40
1802	53	10,2			24			309,4519		422	85,11357		105
1803	54	9,8			13			314,4113		238	86,19186		125
1804	55	8,2			12			319,3706		94	87,27014		86
1805	56	7,8			3			324,33		256	88,34842		125
1806	57	2,2			10			329,2894		88	89,4267		105
1807	58	2	2	3	3,7	1	3,8	334,2487	280	260	90,50498	120	104
1808	59	10,64592	7	0	18,16278	8	1,2	339,2081	200	122	91,58326	120	23
1809	60	10,75273	11	7	18,43898	24	8	344,1675	480	120	92,66154	120	61
1810	61	10,85955	7	3,8	18,71519	2	2,8	349,1268	280	82	93,73982	40	49
1811	62	10,96637	2	1,55	18,9914	4	3,2	354,0862	200	87	94,8181	120	46
1812	63	11,07318	7	5,28	19,26761	12	7,9	359,0456	160	138	95,89638	120	74

Izvor: Izrada autora prema podacima poduzeća Hilding Anders

*Razdoblje od 8. tjedna 2018 do 12. tjedna 2018. godine

7. Literatura

2. Bahovec, V. i Erjavec N.: Uvod u ekonometrijsku analizu, Element, Zagreb, 2009.
3. Bahovec, V. i Erjavec N. i ostali autori: Statistika, Element, Zagreb, 2015.
4. Biljan-August, M.;Pivac, S.; Štambuk, A.: Uporaba statistike u ekonomiji, Rijeka, Ekonomski fakultet Sveučilišta, Rijeka, 2009.
5. Berenson, M. L.: Basic business statistic, New Jersey: Prentice Hall, 2012.
6. Bolfek, B.: Prognoziranje i praćenje dobiti (gubitka) u trgovačkom društvu, Ekonomski pregled, 2005.
7. Dumičić, K. i Bahovec, V. i ostali autori.: Poslovna statistika, Element, Zagreb, 2011.
8. Ferišak, V.: Nabava: politika, strategija, organizacija, managment, Vlastita naklada, Zagreb, 2006.
9. Lovrić, Lj.: Uvod u ekonometriju, Rijeka, Ekonomski fakultet Sveučilišta, 2005.
10. Papić, M.: Primijenjena statistika u MS Excelu, Naklada Zoro, Zagreb, 2014.
11. Šošić, I.: Primijenjena statistika, Školska knjiga, Zagreb, 2006.
12. Interni izvori tvrtke Hilding Anders
13. Službena prezentacija tvrtke Hilding Anders
14. Cronata, nabavna akademija u 3 modula

Internet izvori:

1. https://lider.media/znanja/forecasting-vjestina-za-uspjesno-vodenje-nabave
2. http://www.progressive.com.hr/component/content/article/62-kolumne/1445-forecasting-poslovno-planiranje-.html
3. http://www.hildinganders.com/markets/croatia/hr
4. http://www.jatrgovac.com/2018/02/strategija-poslovanja-planiranje-nabave/
5. https://lider.media/znanja/forecasting-vjestina-za-uspjesno-vodenje-nabave/
6. http://www.efos.unios.hr/imijoc/wp-content/uploads/sites/71/2013/09/Primjena-statisti%C4%8Dkih-metoda-s-naglaskom-na-trend-korelaciju-i-regresiju.pdf
7. https://hespo.hr/

POPIS TABLICA

Tablica 1 Analiza forcasta, prodane i proizvedene količine madraca za Jysk i madraca ukupno47
Tablica 2 Potrošnja materijala za razdoblje 1802-1812 52

POPIS SLIKA

Slika 1 Tijek ekonometrijskog istraživanja.....8
Slika 2 Hilding Anders i Hilding Croatia - Neto prodajni rezultati 34
Slika 3 Neto prodajni rezultati izraženi brojčano..... 35
Slika 4 Organizacijska struktura poduzeća Hilding Anders..... 36
Slika 5 Potrošnja za R110036006 SPUŽVA BLOK PU2337 RED 161020301200 u komadima 49
Slika 6 Potrošnja materijala R100360007 SPUŽVA BLOK PU2337 RED 181020301200 u komadima..... 50
Slika 7 Potrošnja materijala R1020820018 ŽIČANA JEZGRA PO 5Z 1.65/1.8 0F 078018600125 u komadima..... 50
Slika 8 Potrošnja materijala R1020820021 ŽIČANA JEZGRA PO 5Z 1.65/1.8 0F 149018600125 u komadima..... 51

Sveučilište
Sjever

SVEUČILIŠTE
SJEVER

IZJAVA O AUTORSTVU
I
SUGLASNOST ZA JAVNU OBJAVU

Završni/diplomski rad isključivo je autorsko djelo studenta koji je isti izradio te student odgovara za istinitost, izvornost i ispravnost teksta rada. U radu se ne smiju koristiti dijelovi tuđih radova (knjiga, članaka, doktorskih disertacija, magistarskih radova, izvora s interneta, i drugih izvora) bez navođenja izvora i autora navedenih radova. Svi dijelovi tuđih radova moraju biti pravilno navedeni i citirani. Dijelovi tuđih radova koji nisu pravilno citirani, smatraju se plagijatom, odnosno nezakonitim prisvajanjem tuđeg znanstvenog ili stručnoga rada. Sukladno navedenom studenti su dužni potpisati izjavu o autorstvu rada.

Ja, Tatjana Grabant *(ime i prezime)* pod punom moralnom, materijalnom i kaznenom odgovornošću, izjavljujem da sam isključivi autor/ica završnog/diplomskog (*obrisati nepotrebno*) rada pod naslovom Prognoziranje nabave u poduzeću Hilding Anders d.o.o. *(upisati naslov)* te da u navedenom radu nisu na nedozvoljeni način (bez pravilnog citiranja) korišteni dijelovi tuđih radova.

Student/ica:
(upisati ime i prezime)
Grabant Tatjana
(vlastoručni potpis)

Sukladno Zakonu o znanstvenoj djelatnost i visokom obrazovanju završne/diplomske radove sveučilišta su dužna trajno objaviti na javnoj internetskoj bazi sveučilišne knjižnice u sastavu sveučilišta te kopirati u javnu internetsku bazu završnih/diplomskih radova Nacionalne i sveučilišne knjižnice. Završni radovi istovrsnih umjetničkih studija koji se realiziraju kroz umjetnička ostvarenja objavljuju se na odgovarajući način.

Ja, Tatjana Grabant *(ime i prezime)* neopozivo izjavljujem da sam suglasan/na s javnom objavom završnog/diplomskog (*obrisati nepotrebno*) rada pod naslovom Prognoziranje nabave u poduzeću Hilding Anders d.o.o. *(upisati naslov)* čiji sam autor/ica.

Student/ica:
(upisati ime i prezime)
Grabant Tatjana
(vlastoručni potpis)