

UNIVERZA V LJUBLJANI
FAKULTETA ZA RAČUNALNIŠTVO IN INFORMATIKO

Gregor Belčec

Napovedovanje povpraševanja

DIPLOMSKO DELO
NA UNIVERZITETNEM ŠTUDIJU

Ljubljana, 2011

UNIVERZA V LJUBLJANI
FAKULTETA ZA RAČUNALNIŠTVO IN INFORMATIKO

Gregor Belčec

Napovedovanje povpraševanja

DIPLOMSKO DELO
NA UNIVERZITETNEM ŠTUDIJU

Mentor: izr. prof. dr. Marko Bajec

Ljubljana, 2011



Št. naloge: 01727/2011

Datum: 15.03.2011

Univerza v Ljubljani, Fakulteta za računalništvo in informatiko izdaja naslednjo nalogo:

Kandidat: **GREGOR BELČEC**

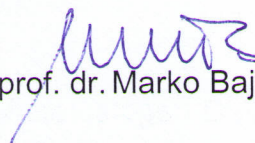
Naslov: **NAPOVEDOVANJE POVPRASEVANJA
DEMAND FORECASTING**

Vrsta naloge: Diplomsko delo univerzitetnega študija

Tematika naloge:


Napovedovanje povpraševanja je ena pomembnejših nalog, še posebej v proizvodnih podjetjih. Z izboljšavo napovedi lahko znižamo stroške v različnih delih oskrbovalne verige, povečamo zanesljivost podatkov ter kvaliteto same storitve. V okviru diplomske naloge preučite področje napovedovanja povpraševanja ter izdelajte računalniško rešitev bodisi za namišljeno ali konkretno podjetje.

Mentor:


prof. dr. Marko Bajec



Dekan:


prof. dr. Nikolaj Zimic

Rezultati diplomskega dela so intelektualna lastnina Fakultete za računalništvo in informatiko Univerze v Ljubljani. Za objavljanje ali izkoriščanje rezultatov diplomskega dela je potrebno pisno soglasje Fakultete za računalništvo in informatiko ter mentorja.

Besedilo je oblikovano z urejevalnikom besedil \LaTeX .

IZJAVA O AVTORSTVU

diplomskega dela

Spodaj podpisani Gregor Belčec,

z vpisno številko 63050010,

sem avtor diplomskega dela z naslovom:

Napovedovanje povpraševanja

S svojim podpisom zagotavljam, da:

- sem diplomsko delo izdelal samostojno pod mentorstvom izr. prof. dr. Marka Bajca
- so elektronska oblika diplomskega dela, naslov (slov., angl.), povzetek (slov., angl.) ter ključne besede (slov., angl.) identični s tiskano obliko diplomskega dela
- soglašam z javno objavo elektronske oblike diplomskega dela v zbirki "Dela FRI".

V Ljubljani, dne 15.06.2011

Podpis avtorja:

Zahvala

Zahvaljujem se mentorju izr. prof. dr. Marku Bajcu za strokovno pomoč in usmerjanje pri izdelavi diplomskega dela.

Iskrena hvala tudi Marku Tanku za nasvete in pomoč pri izdelavi diplomskega dela.

Nenazadnje pa se zahvaljujem še družini za podporo in vrsto spodbud v letih študija.

Kazalo

Povzetek	1
Abstract	2
1 Uvod	3
1.1 Motivacija	3
1.2 Pregled vsebine	4
2 Napovedovanje	5
2.1 Napovedovanje povpraševanja	5
2.2 Pomen napovedovanja	6
2.3 Modeli napovedovanja	6
2.3.1 Kvantitativni modeli	7
2.3.2 Kvalitativni modeli	8
2.4 Smernice za izbiro modela napovedovanja	9
2.5 Časovne vrste	10
2.5.1 Trend in cikel	12
2.5.2 Sezonskost	12
2.5.3 Naključna nihanja	12
3 Napovedovanje povpraševanja v podjetju Danfoss Trata, d. o. o.	15
3.1 Danfoss District Energy	15
3.2 Proces napovedovanja povpraševanja	17
3.3 Uporabna vrednost napovedi v različnih okoliščinah	22
3.3.1 Izdelki tipa A	22
3.3.2 Izdelki tipa B	24
3.3.3 Izdelki tipa C	25
3.3.4 Projektna prodaja	26

4	Algoritem napovedovanja povpraševanja	29
4.1	Vhodni podatki	31
4.1.1	Seznam izdelkov	31
4.1.2	Prodajne informacije	32
4.1.3	Zgodovinska prodaja	33
4.1.4	Ročno podana sezonskost	33
4.1.5	Globalne spremenljivke	34
4.1.6	Ročni popravki na nivoju družine izdelkov	35
4.1.7	Ročni popravki na nivoju izdelka	36
4.2	Modeli napovedovanja	37
4.2.1	Od spodaj navzgor V1	38
4.2.2	Od zgoraj navzdol V1	44
4.2.3	Od spodaj navzgor V2	48
4.2.4	Od zgoraj navzdol V2	49
4.2.5	Povprečje	50
4.2.6	Pretrgane časovne vrste	50
4.3	Natančnost napovedi	52
5	Zaključek	55
A	Forecast Explorer	57
A.1	Opis	57
A.2	Uporabljene tehnologije	62
	Seznam slik	63
	Seznam tabel	64
	Literatura	65

Povzetek

Podjetja delujejo v vse bolj zahtevnem okolju, kar od njih zahteva stalne izboljšave na vseh področjih poslovnega procesa. Eno izmed področij v proizvodnih podjetjih, kjer se lahko nadejamo velikih koristi od izboljšav, je napovedovanje povpraševanja. Izboljšave v napovedi lahko prinesejo znižanje stroškov v celotni oskrbovalni verigi, izboljšajo zanesljivost informacij ter kvaliteto storitve za naše stranke. V podjetju Danfoss Trata, d. o. o. nismo imeli sistema za napovedovanje povpraševanja oziroma se je napoved izdelovala na podlagi zgodovinskih podatkov in občasnih informacij s trga. Sistem za napovedovanje povpraševanja je bila tako nujno potrebna izboljšava. Kljub različnim rešitvam, ki jih lahko najdemo na trgu, smo se odločili za izdelavo lastne. Pomembni prednosti lastne rešitve sta bili cena razvoja in implementacije ter vključenost uporabnikov v razvoj in nadgradnjo procesa. Uporabniki so namreč na ta način pridobili poglobljeno razumevanje faktorjev, ki vplivajo na napoved. Največji izziv pri izdelavi lastne rešitve je bila izdelava lastnega algoritma napovedovanja, ki temelji na specifičnem poslovnem okolju, v katerem se nahaja podjetje Danfoss Trata, d. o. o. V diplomskem delu je tako najprej predstavljeno področje napovedovanja povpraševanja ter zakaj je napovedovanje tako pomembno. Podanih je tudi nekaj smernic za izbiro najprimernejšega modela napovedovanja in predstavitev časovnih vrst, katerih razumevanje je imelo pomembno vlogo pri izdelavi lastnega algoritma napovedovanja. Sledi predstavitev novega procesa napovedovanja v podjetju Danfoss Trata, d. o. o. in uporabne vrednosti napovedi v različnih okoliščinah. Na koncu je podrobno predstavljen še sam algoritem napovedovanja, ki je bil nato implementiran v Danfossovem sistemu za napovedovanje povpraševanja.

Ključne besede:

Napovedovanje povpraševanja, časovne vrste, statistični modeli, upravljanje oskrbovalne verige, planiranje povpraševanja.

Abstract

Companies operate in an increasingly challenging environment that requires them to continuously improve all areas of the business process. Demand forecasting is one area in manufacturing companies where we can hope to gain great advantages. Improvements in forecasting can result in cost savings throughout the supply chain, improve the reliability of information and the quality of the service for our customers. In the company Danfoss Trata, d. o. o. we did not have a system for demand forecasting. The forecast was made on the basis of historical data and occasional information from the market. The use of a demand forecasting system was thus an urgently needed improvement. Despite the various solutions found on the market today we have decided to create our own forecasting system. The cost of development and implementation, and user involvement in the development and upgrade of process were two important advantages of this. Users have thus gained a deeper understanding of the factors affecting the forecast. The biggest challenge was creating our own forecasting algorithm, based on the specific business environment in which the company Danfoss Trata, d. o. o. operates. Thus, the first part of the diploma paper includes an introduction to the field of demand forecasting as well as an explanation on why forecasting is so important. It includes a few guidelines for selecting the most appropriate forecasting model and introduces time series, the understanding of which has played an important role when developing our own forecasting algorithm. This is followed by an introduction of the new forecasting process of the company Danfoss Trata, d. o. o. and the value of forecasts in various circumstances. In the end, the forecasting algorithm, which was later implemented in the Danfoss demand forecasting system, is presented in detail.

Key words:

Demand forecasting, time series, statistical models, supply chain management, demand planning.

Poglavje 1

Uvod

1.1 Motivacija

Podjetja delujejo v vse bolj zahtevnem okolju, kar od njih zahteva stalne izboljšave na vseh področjih poslovnega procesa. Eno izmed področij v proizvodnih podjetjih, kjer se lahko nadejamo velikih koristi od izboljšav, je napovedovanje povpraševanja („Demand forecasting“). Izboljšave v napovedi lahko prinesejo znižanje stroškov v celotni oskrbovalni verigi, izboljšajo zanesljivost informacij ter kvaliteto storitve za naše stranke [7].

Z željo po izboljšavah smo v podjetju Danfoss Trata, d. o. o. proučili trenutno stanje. Ena izmed pomembnih stvari, ki smo jih morali spremeniti, je bila vpeljava sistema za napovedovanje povpraševanja. Pred vpeljavo sistema napovedovanja je namreč napovedovanje potekalo ročno. Na voljo smo imeli tri možnosti: investicija v komercialno rešitev višjega cenovnega razreda (SAP APO, Oracle Demantra) ali srednjega cenovnega razreda (Forecast Pro) ter izdelava lastne rešitve [7]. Odločili smo se za slednjo, in sicer na podlagi dveh razlogov. Stroški lastne rešitve so bili neprimerno manjši od nakupa komercialne rešitve višjega cenovnega razreda. Ker je bilo izredno težko upravičiti veliko naložbo v sistem napovedovanja brez vnaprej znanih prihrankov, smo se nagibali k cenejšim rešitvam. Drugi pomemben razlog pa je bila potreba po izboljšavi procesa napovedovanja, kar je bilo lažje doseči v primeru, da smo ga zgradili na novo. Uporabniki so namreč na ta način pridobili poglobljeno razumevanje faktorjev, ki vplivajo na napoved. Največji izziv pri izdelavi lastne rešitve je bila izdelava lastnega algoritma napovedovanja, ki temelji na specifičnem poslovnem okolju, v katerem se nahaja podjetje Danfoss Trata, d. o. o. Algoritem napovedovanja, ki je bil implementiran v Danfossovem sistemu za napovedovanje povpraševanja, je podrobno predstavljen v okviru

diplomskega dela.

1.2 Pregled vsebine

Diplomsko delo je razdeljeno na pet poglavij.

Prvo poglavje predstavlja uvod v diplomsko delo ter podaja razlog za odločitev o izdelavi lastne rešitve za napovedovanje povpraševanja.

V drugem poglavju je predstavljeno področje napovedovanja povpraševanja ter zakaj je napovedovanje tako pomembno. Podanih je tudi nekaj smernic za izbiro najprimernejšega modela napovedovanja in predstavitev časovnih vrst, katerih razumevanje je imelo pomembno vlogo pri izdelavi lastnega algoritma napovedovanja.

V tretjem poglavju sledi predstavitev novega procesa napovedovanja v podjetju Danfoss Trata, d. o. o. in uporabna vrednost napovedi v različnih okoliščinah.

V četrtem poglavju je nato podrobno predstavljen algoritem napovedovanja povpraševanja. Zadnje peto poglavje predstavlja zaključek diplomskega dela.

Poglavje 2

Napovedovanje

Napovedovanje je ocenjevanje bodočih dogodkov oziroma dejavnosti [4]. Natančneje; z napovedovanjem poskušamo podati ocene o bodočih dogodkih v pogojih negotovosti. Če bodoči dogodki predstavljajo samo merljive spremembe preteklih dogodkov, lahko prihodnje dogodke dokaj enostavno napovemo s projekcijo zgodovinskih trendov. Vendar pa napovedovanje ni samo projekcija preteklih dogodkov v prihodnost [3].

Pri napovedovanju lahko hitro ugotovimo, da bodoči dogodki niso samo matematična funkcija dogodkov v preteklosti. Različne matematične abstrakcije, kot so trend, sezonskost („Seasonality“) ter cikli, so seveda v veliko pomoč pri izdelavi napovedi, vendar moramo v napovedovanje vključiti tudi druge sestavine [3]. V poslovnem svetu se recimo soočamo z različnimi pogoji poslovanja, ki se skozi čas spreminjajo. Tako je lahko pri napovedovanju v veliko pomoč mnenje članov poslovnega procesa, ki imajo edinstven vpogled v bodoče potencialne spremembe v poslovanju.

Napoved ni končni izdelek, je le vhod v proces planiranja v podjetju. V osnovi služi kot vodilo planerjem in vodstveni ekipi, ki sprejemajo poslovne odločitve v povezavi s potrebnimi proizvodnimi kapacitetami, potrebnimi zalogami proizvodov in nabavo vhodnih materialov. Napoved predstavlja oceno bodočih vrednosti določenih spremenljivk pri normalnih pogojih poslovanja [3].

2.1 Napovedovanje povpraševanja

Napovedovanje kot del procesa upravljanja s povpraševanjem poskuša oceniti prihodnje povpraševanje potrošnikov po proizvodih in storitvah podjetja. Točne napovedi pripomorejo k bolj predvidljivemu in tekočemu delu v proi-

zvodnji, nabavi, distribuciji in prodajnih operacijah podjetij. Napoved prave količine, pravega proizvoda ob pravem času in na pravem mestu je temelj napovedovanja v okviru oskrbovalne verige [3].

Pred začetkom procesa napovedovanja je potrebno identificirati vse potrebne sestavine, ki jih potrebujemo za izdelavo napovedi. Mednje spadajo iskanje virov podatkov o predmetu napovedi, zgodovinskih podatkov o prodaji, določanje zunanjih dejavnikov, ki lahko vplivajo na napoved, določanje potreb uporabnikov napovedi, zbiranje človeških in finančnih sredstev za izdelavo napovedi ter izbira metod napovedovanja. Pred izdelavo napovedi moramo določiti tudi obliko napovedi oziroma način, kako bomo napoved predstavili končnim uporabnikom, kar pa je seveda odvisno od njihovih potreb [3].

Izdelek procesa napovedovanja je konkretna napoved povpraševanja. Napovedi se ne sme obravnavati statično, saj mora odražati spremembe trga in jo je tako potrebno stalno posodablјati. Vrednost napovedi se meri glede na korist, ki jo nudi nosilec odločanja. Da pa bi bila napoved koristna, mora v vsakem trenutku odražati najbolj aktualno stanje na trgu [3].

2.2 Pomen napovedovanja

Pogosto pride do razlike v času med zavedanjem, da bo prišlo do nekega dogodka, in dejanskim dogodkom. Dolžina tega vmesnega časa je razlog za napovedovanje. V primeru dolgega vmesnega časa ni potrebe po napovedovanju, saj bo podjetje imelo dovolj časa za pripravo na dogodek, ko bo dobilo informacijo, da se bo le-ta zgodil. V nasprotnem primeru, ko je ta čas kratek, podjetje nima časa za pripravo, temveč mora določene stvari izvesti predčasno. Le-te naredi na podlagi napovedi. Osnovna naloga napovedovanja je določitev časa in obsega dogodka, da se podjetje lahko pripravi nanj (pri nabavi vhodnih materialov, proizvodnji, določanju zalog ipd.). Napovedovanje predstavlja pomemben pripomoček za učinkovito planiranje [5].

Napovedovanje je tako zelo pomembno v upravljanju in administraciji, saj lahko vmesni časi pri odločanju znašajo od nekaj sekund (upravljanje z električnimi omrežji) do nekaj ur ali dni (planiranje proizvodnje) [5].

2.3 Modeli napovedovanja

Obstajajo različne okoliščine napovedovanja, ki se med seboj razlikujejo glede na časovna obdobja; oblike vzorcev v podatkih; faktorje, ki vplivajo na na-

poved, in druge vidike. Za različne okoliščine so bili razviti različni modeli. Modele, ki se uporabljajo v napovedovanju, lahko razvrstimo v dve glavni skupini: kvantitativni in kvalitativni modeli [5].

2.3.1 Kvantitativni modeli

Kvantitativne modele lahko uporabimo, kadar je zadoščeno naslednjim trem pogojem [5]:

1. Na voljo imamo dovolj informacij o preteklosti.
2. Te informacije je možno izraziti v obliki numeričnih podatkov.
3. Lahko predpostavimo, da se bodo nekateri zgodovinski vzorci nadaljevali v prihodnosti.

Kvantitativne modele lahko razdelimo še v dve podskupini: statistični modeli in deterministični modeli [3]:

Statistični modeli

Statistični modeli se v literaturi pojavljajo tudi pod imenom modeli časovnih vrst [5], [1].

Statistični modeli obravnavajo sistem kot črno škatlo in tako ne upoštevajo morebitnih zunanjih faktorjev, ki bi lahko vplivali na obnašanje sistema. Posledično je napoved rezultat analize preteklih podatkov določene spremenljivke. Cilj te vrste modelov je poiskati vzorec v preteklih podatkih in projicirati ta vzorec v prihodnost. To vrsto modelov imenujemo tudi univariantni modeli, saj potrebujemo za izdelavo napovedi samo podatke spremenljivke, ki jo napovedujemo [3].

Obstajata dva razloga, zakaj želimo obravnavati sistem kot črno škatlo. Prvi razlog je, da sistema ne razumemo oziroma bi bilo zelo težko določiti relacije, ki določajo njegovo obnašanje. Drugi razlog je, da želimo vedeti le, kako se bo sistem obnašal v prihodnosti in ne zakaj se bo tako obnašal [5].

Med standardne statistične modele spadajo: drseče povprečje, eksponentno glajenje, dekompozicija časovnih vrst ter ARIMA modeli [3], [5], [1].

Deterministični modeli

Deterministični modeli se v literaturi pojavljajo tudi pod imenoma razlagalni modeli („Explanatory models“) [5] in modeli vzrok-in-učinek („Cause-and-effect models“) [1].

Deterministični modeli predpostavljajo, da obstaja relacija med spremenljivko, katere vrednost želimo napovedati, in eno ali več neodvisnimi spremenljivkami. Če je prodajna količina odvisna od količine sredstev, namenjenih oglaševanju, je prodajna količina odvisna spremenljivka ter količina sredstev neodvisna spremenljivka. Cilj te vrste modelov je poiskati relacije v podatkih in jih uporabiti pri napovedovanju. Glede na deterministične modele naj bi se vsaka sprememba na vhodu odrazila na izhodu sistema [5].

Med standardne deterministične modele spadajo: regresija, ekonometrija ter nevronske mreže. [1]

2.3.2 Kvalitativni modeli

Kvalitativni modeli se v literaturi pojavljajo tudi pod imenom modeli na osnovi ekspertnega znanja („Judgmental models“) [1].


Namen kvalitativnih modelov je, da na logičen, nepristranski in sistematični način združijo vse informacije, ki se nanašajo na določen problem. Zbrane kvalitativne podatke nato s pomočjo ekspertnega znanja pretvorijo v numerične podatke [2]. Za razliko od kvantitativnih modelov, katerih vhod so numerični podatki, je vhod v kvalitativne modele ekspertno znanje [5].

Pri kvalitativnih modelih se ne osredotočamo toliko na natančnost napovedi, saj služijo bolj kot vodilo planerjem. Uporabljajo se predvsem v srednjeročnih in dolgoročnih situacijah, kot so izdelava strategij, razvoj novih izdelkov in tehnologij ter dolgoročno planiranje [5].

Ti modeli so uporabni v primeru, ko nimamo na voljo zgodovinskih podatkov. Tak primer so novi izdelki [4].

Med standardne kvalitativne modele spadajo: Delfi metoda, tržne raziskave, odločitvena drevesa, igranje vlog [5],[1].

Leta 2007 je bila narejena raziskava uporabe različnih modelov napovedovanja. 61 % podjetij v raziskavi je za napovedovanje uporabljalo statistične, 18 % podjetij deterministične in 15 % podjetij kvalitativne modele. 5 % podjetij je uporabljalo modele, ki so jih razvili sami. Tak vzorec je bilo opaziti v vseh industrijah. Statistični modeli so bili najbolj uporabljeni predvsem zaradi svoje enostavnosti in ker v splošnem dajejo dobre rezultate pri kratkoročnem napovedovanju [1]. Slika 2.1 prikazuje rezultate raziskave.



Slika 2.1: Prikaz deležev uporabe različnih modelov napovedovanja [1].

2.4 Smernice za izbiro modela napovedovanja

Pri izbiri pravega modela je potrebno upoštevati določene smernice [1]:

- **Dejanska vrednost = vzorec + napaka**

Podatki vsebujejo določen vzorec. Potrebno je poiskati model, ki bo v čim večji meri zaobjel vzorec in bo tako manjši del predstavljal napako.

- **Na potrebuje 100% natančnosti**

Naloga modela je čim bolj zmanjšati napako, vendar ni potrebe po 100% natančnosti. Večina podjetij lahko kompenzira določena odstopanja. V proizvodnji bodo tako vedno imeli varnostno zalogo za primer napake.

- **Sofisticirani modeli niso nujno tudi boljši**

Najboljša strategija je, da začnemo z enostavnim modelom in nadaljujemo proti bolj sofisticiranim modelom, dokler ne dosežemo zahtevane natančnosti. Če je zahtevano, da je napaka 3% ali manj, zadostuje model, ki ima napako 3%. Poleg tega je delovanje enostavnih modelov lažje pojasniti vodstvu.

- **Ni univerzalnega modela**

Različni podatki vsebujejo različne vzorce in za različne vzorce obstajajo različni modeli. Težko je najti model, ki bi bil primeren za vse situacije.

- **Modeli se starajo**

Če smo našli pravi model, še ne pomeni, da bo primeren tudi v prihodnosti. Poslovno okolje se stalno spreminja in skladno s tem se mora spreminjati tudi model. Pomembno je, da delovanje modela spremljamo skozi čas in če ni več primeren, poiščemo novega.

- **Vsak model ima svoje podatkovne zahteve**

Različni modeli imajo različne podatkovne zahteve. Nekateri potrebujejo več zgodovinskih podatkov, drugi podatke o več različnih spremenljivkah.

- **Statistična napoved je samo osnova končne napovedi**

Noben model ne upošteva vseh možnih spremenljivk. Statistično napoved lahko popravimo na podlagi znanja in izkušenj planerjev, ki jih ni bilo mogoče numerično izraziti oziroma jih nismo poznali v času izdelave napovedi. Tako je statistična napoved le osnova končne napovedi.

- **Priprava napovedi ne sme biti izolirana**


Pri izdelavi napovedi moramo upoštevati informacije različnih oseb, saj nihče nima vseh informacij. Pri napovedi moramo tako vključiti ljudi z različnih področij, kot so prodaja, trženje, finance itd.

2.5 Časovne vrste

Algoritem napovedovanja povpraševanja, ki bo predstavljen v nadaljevanju se v veliki meri opira na teorijo časovnih, zato bomo na tem mestu opredelili kaj časovne vrste so, kako so povezane z napovedovanjem in navedli nekatere njihove lastnosti.

Zgodovinski podatki so pogosto sestavljeni iz zaporednih opazovanj v času. Tem zaporedjem pravimo časovne vrste. Primeri časovnih vrst so: vrednost mesečne prodaje, dnevna vrednost delnic, maksimalne temperature dneva itd. Z napovedovanjem poskušamo oceniti, kako se bo zaporedje opazovanj nadaljevalo v prihodnosti [5].

Pri napovedovanju poslovanja pogosto predpostavljamo, da lahko časovne vrste izrazimo s štirimi osnovnimi komponentami: trendom, ekonomskim ciklom, sezonskostjo in naključnimi nihanji [3].



Slika 2.2: Prikaz dekompozicije časovne vrste na osnovne komponente [10].

2.5.1 Trend in cikel

Pri napovedovanju se beseda trend pogosto navezuje na projekcijo s premico, vendar lahko trend vsebuje tudi bolj zapleten vzorec. Pri obravnavi časovnih vrst govorimo o trendu takrat, kadar lahko v nekem vzorcu opazimo prevladujočo rast oziroma padec skozi čas. Kot primer lahko navedemo vrednost mesečne prodaje veliko podjetij [3].

O ciklih govorimo takrat, kadar se v podatkih pojavljajo nihanja, katerih dolžina in amplituda nista konstantni. Ta karakteristika ciklov zelo oteži napovedovanje. Kljub temu, da veliko ekonomskih časovnih vrst vsebuje cikle, je njihova merljivost ena izmed bolj izmikajočih se področij v analizi časovnih vrst [3].

V praksi se pogosto trend in cikel obravnavata kot ena komponenta imenovana trend-cikel [3].


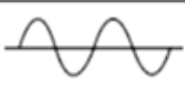
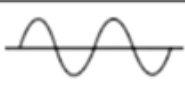







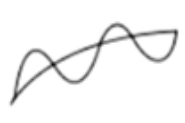

2.5.2 Sezonskost

Najbolj pogosto se sezonskost nanaša na redna periodična nihanja, ki se ponavljajo vsako leto približno ob istem času in z enako intenziteto. Sezonskost se lahko pojavi tudi kot nihanje znotraj meseca, tedna oziroma dneva. Kot primer lahko omenimo povečanje vrednosti prodaje vsako leto pred božičnimi prazniki [3].

2.5.3 Naključna nihanja

V to kategorijo spadajo vsi vzorci, ki jih ne moremo povezati s trend-ciklom oziroma sezonskostjo. Naključna nihanja pogosto predstavljajo težavo za napovedovalce, saj so v splošnem nepredvidljivi. Naključna nihanja so sestavljena iz netipičnih opazovanj, ki so lahko posledica nenavadnih ali redkih dogodkov, napak pri prepisovanju, administrativnih odločitev in naključnih variacij [3].

Pri izbiri najprimernejše metode napovedovanja je pomembno, da pretehtamo različne vzorce v podatkih. Za napovedovanje na podlagi podatkov, katerih časovne vrste vsebujejo trend in sezonskost, obstajajo različne metode. Vsaka izmed metod ima svoj profil napovedovanja, ki se kaže kot vzorec napovedi, izdelane z uporabo izbrane metode. Različne profile lahko klasificiramo z uporabo Pegelsovih diagramov [3].

	Brez sezonskosti	Aditivna sezonskost	Multiplikativna sezonskost
Konstantna raven			
Linearni trend			
Eksponentni trend			
Dušeni trend			

Slika 2.3: Prikaz različnih vzorcev glede na Pegelsovo klasifikacijo [3].

Profile napovedovanja lahko klasificiramo v dveh smereh, in sicer glede na profil trenda in sezonskosti. Po Pegelsovi klasifikaciji obstajajo štirje profili trenda in trije sezonskosti.

Profili trenda (veljajo tako za rast kot padec):

- **Konstantna raven**

Brez trenda.

- **Linearni trend**

Konstantna količina spremembe na periodo.

- **Eksponentni trend**

Konstantni stopnja spremembe na periodo.

- **Dušeni trend**

Rast oziroma padec, ki počasi zamira.

Profili sezonskoti:

- **Brez sezonskosti**

- **Aditivna sezonskost**

Amplituda sezonskih nihanja se ne spreminja s časom.

- **Multiplikativna sezonskost**

Amplituda sezonskih nihanj se povečuje skladno s povečevanjem letnega povprečja.

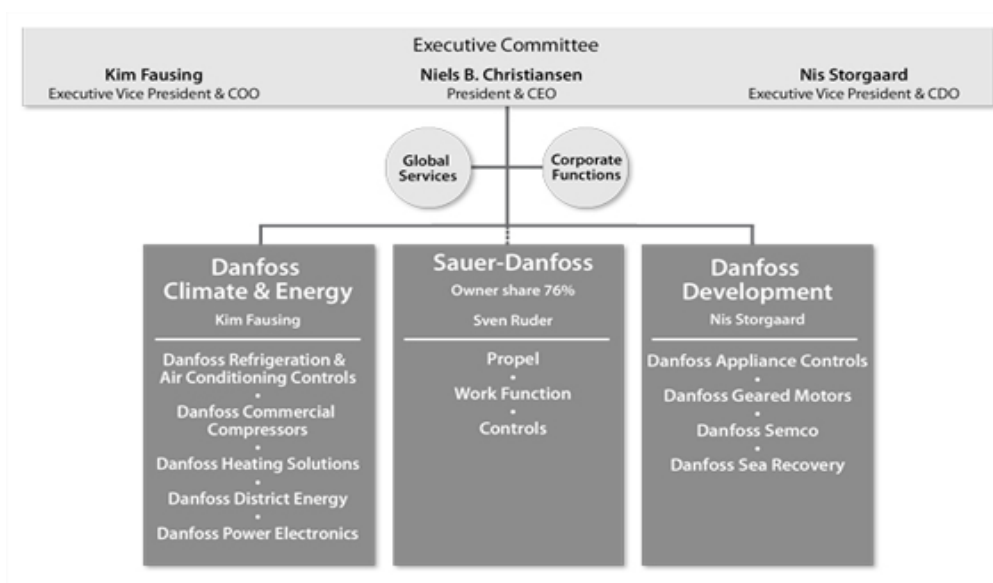
Poglavje 3

Napovedovanje povpraševanja v podjetju Danfoss Trata, d. o. o.

3.1 Danfoss District Energy

Danfoss je mednarodno podjetje v zasebni lasti in je eno izmed največjih industrijskih podjetij na Danskem. Podjetje je leta 1933 ustanovil Mads Clausen. Podjetje je od ustanovitve dalje ves čas raslo. Sedaj obsega preko 23.000 zaposlenih. Danfoss svoje izdelke in storitve ponuja na svetovnem trgu preko dobro razvite prodajne mreže, ki obsega 115 prodajnih organizacij in prav toliko agentov ter distributerjev. Svoje izdelke proizvajajo v 93 podjetjih v 25 državah. Podjetje je danes vodilno na področju razvoja in proizvodnje mehanških ter elektronskih komponent na področju ogrevanja, hlajenja in gibalnih sistemov [8].

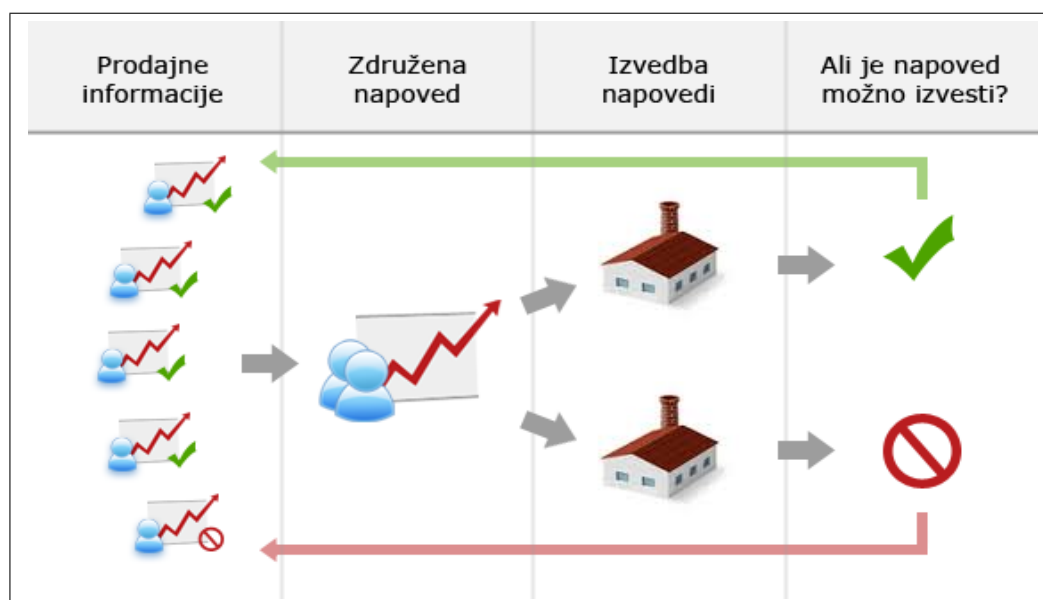
Skupina Danfoss je razdeljena v tri stebre. Prvi, Danfoss Climate & Energy, predstavlja temeljne poslovne aktivnosti skupine. Te so razdeljene v pet divizij, ki delujejo večinoma samostojno. Ena izmed njih je tudi Danfoss District Energy, katere del je slovensko podjetje Danfoss Trata, d. o. o. Danfoss Trata, d. o. o. je del skupine Danfoss postala leta 1995. Drugi steber, Danfoss Development, predstavlja aktivnosti, ki bodo v prihodnosti predmet ponovnih strateških ocen z namenom prodaje, skupnega prevzemanja tveganja in drugih poslovnih vez. Tretji steber predstavlja delniško podjetje Sauer-Danfoss, kjer ima Danfoss 76% lastniški delež. Sauer-Danfoss je vodilno mednarodno podjetje za mobilno hidravliko [8].



Slika 3.1: Prikaz organizacije skupine Danfoss [8].

Divizija Danfoss District Energy ima vodilni tržni delež na področju regulacije daljinskega ogrevanja na svetu. Svoje izdelke razvija in proizvaja v Sloveniji, na Danskem, Finskem, Poljskem, v Rusiji, Romuniji, Avstriji, Švici in na Kitajskem. V diviziji so vzpostavljene tri glavne poslovne enote: komponente, toplotne podpostaje in izmenjevalniki toplote. Slovensko podjetje Danfoss Trata, d. o. o. upravlja in razvija poslovno področje komponent za daljinsko ogrevanje ter hlajenje ne le s tehničnega, ampak z odgovornostjo za poslovni rezultat tudi s poslovnega vidika. Strokovnjaki in vodje Danfoss Trate, d. o. o. predvsem iz razvojno-tehničnega, proizvodnega in logističnega področja uspešno delujejo v globalnih projektih in vodijo procese, ki so pomembni za celotno divizijo. V okviru poslovne enote komponent je bil razvit tudi sistem za napovedovanje povpraševanja, katerega pomemben del je algoritem napovedovanja povpraševanja, ki je podrobno predstavljen v diplomskem delu [9].

3.2 Proces napovedovanja povpraševanja



Slika 3.2: Prikaz procesa napovedovanja v podjetju Danfoss Trata, d. o. o.

Osnovna naloga procesa napovedovanja povpraševanja je pretvorba prodajnih pričakovanj v proizvodne količine. Proces napovedovanja povpraševanja sestoji iz sledečih korakov:

1. Zbiranje informacij, ki jih posredujejo prodajniki s posameznih trgov.
2. Avtomatsko generiranje napovedi, ročni vnosi in konsolidacija.
3. Preverjanje celovite napovedi in upravljanje z izjemami.
4. Posredovanje napovedi v sistem SAP.
5. Povratna informacija o izvedljivosti napovedi.

Zbiranje informacij poteka preko posebnega uporabniškega vmesnika, namenjenega prodajnikom. Pri načrtovanju vmesnika smo izhajali iz miselnega procesa prodajnika pri določanju napovedi. Prodajnik je zadolžen za določene družine izdelkov na določenem trgu. Družine izdelkov so naprej razdeljene na posamezne statistične skupine. Statistična skupina združuje različne variacije enega izdelka. Prodajnik pri določanju napovedi izhaja iz pretekle vrednosti

prodaje in njemu poznane situacije na trgu. Vmesnik tako prikaže strukturo statističnih skupin za določeno družino izdelkov s pripadajočimi statistikami vrednosti pretekle prodaje. Za zbiranje informacij je zadolžen planer, ki na sestankih skupaj s prodajniki določi pričakovano rast za naslednje leto po posameznih družinah izdelkov na posameznih trgih. Nato je naloga planerja, da predlagano rast vnese pod ustrezno statistično skupino. Planer dobi od prodajnika informacijo o pričakovani rasti na določeni družini izdelkov, ki jo nato poskusi pripisati ustrezni statistični skupini. Pri tem si pomaga s podatki o dosedanji rasti. V primeru, da planer ne more določiti ustrezne statistične skupine se za pomoč ponovno obrne na prodajnika. Planer lahko dobi informacijo o rasti na določeni družini izdelkov, pri pregledu posameznih statističnih skupin pa opazi, da so imele vse v preteklem letu padec, zato zahteva dodatna pojasnila. Tako želimo razbremeniti prodajnika, saj ga ne obremenjujemo s planiranjem in podatki v situacijah, kjer so le-te predvidljive in stabilne. Od prodajnika se zahtevajo le informacije na najvišjem nivoju, torej informacije o trendih, in le v izrednih primerih („Management by exception,“) na konkretnih grupah izdelkov; v primeru, da se planer ne more sam odločiti kam pripisati določene spremembe.

Zbiranju informacij sledi obdelava podatkov. Tukaj lahko izpostavimo prvo večjo dodano vrednost sistema za napovedovanje povpraševanja – avtomatizacijo, ki v orodjih kot je Excel ni izvedljiva do take stopnje. Sistem namreč pokriva tri pomembne vidike:

- uporaba večih statističnih modelov,
- izbiro najprimernejšega modela s pomočjo vgrajene odločevalne logike planerja,
- avtomatizacijo postopka.

Sistem uporablja za napovedovanje kombinacijo več statističnih modelov, katerim je dodana odločitvena logika planerja. Odločitvena logika planerja predstavlja vključitev različnih izkušenj planerjev v algoritem napovedovanja. Z analizo dela planerja smo poiskali različne tehnike, ki so jih uporabljali pri izdelavi napovedi v preteklosti. Izkušnje planerjev, ki smo jih vključili v algoritem, so sledeče:

- **Popravek napovedi**

V primeru, da je količina prodaje v zadnjih treh mesecih precej manjša (ali obratno večja) od napovedane, se napoved spremeni skladno z določenimi pravili za naslednje tri mesece.

- **Dekompozicija vrednosti prodaje v količino izdelkov**

Vhod v algoritem so vrednosti prodaje, ki predstavljajo pričakovanja prodajnikov. Ta vrednost se nato avtomatično razdeli med posamezne izdelke glede na strukturo vrednosti prodaje v konkretni statistični skupini izdelkov v zadnjih dvanajstih mesecih. Posledica tega je, da se največji del vrednosti pripiše tistemu izdelku, ki ima največji delež in je torej najpomembnejši. S tem se zagotovi plan na „pravih“ izdelkih brez ročnega preverjanja planerja.

- **Način, kako se upošteva sezonskost**


Algoritmi za napovedovanje povpraševanja v splošnem ne uporabljajo fiksno določenih sezonskih period. Za razliko od ostalih modelov in algoritmov smo se v našem primeru na podlagi izkušenj in konkretnega poslovnega okolja Danfossa odločili za uporabo statične sezonske periode enega koledarskega leta, ki ustreza prodajnemu ciklu Danfossovih izdelkov. Sezonskost v tej periodi se izračuna na podlagi zgodovinskih podatkov preteklih dveh let. Ta odločitev je specifična za podjetje Danfoss in je prihranila veliko dodatnega dela pri izdelavi aplikacije, vendar pa to ne pomeni, da je primerna za vsa podjetja.

- **Rezanje in glajenje projektov**

Gre za tehniko, ki podatke, ki zelo odstopajo od povprečja (projektna prodaja), na podlagi določenih pravil ali odreže ali pa zglati ter jih tako ne uporabi pri izdelavi napovedi.

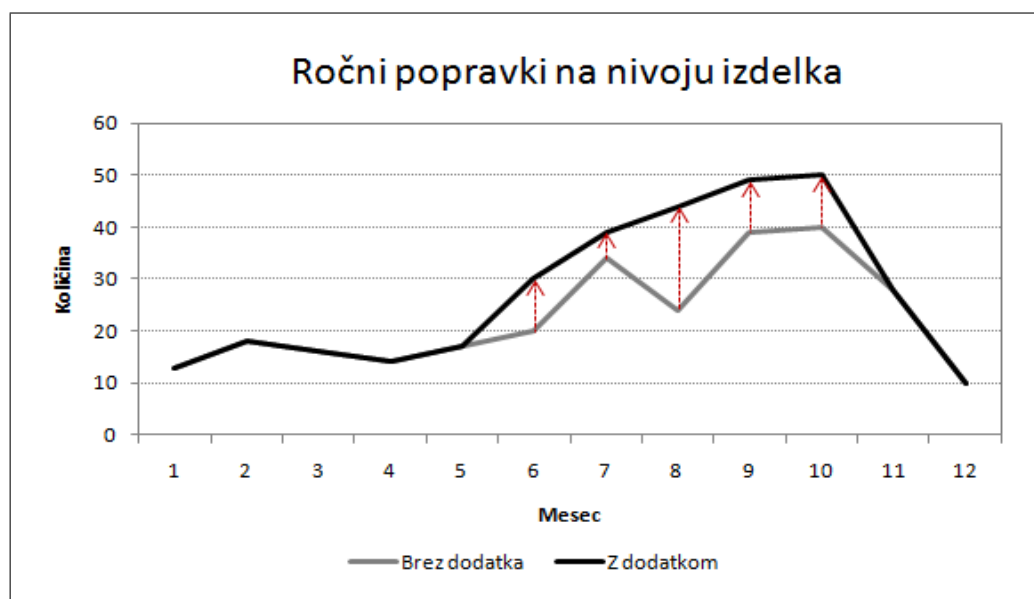
Ena izmed praks, ki se je izkazala za zelo uspešno, je zgoraj omenjeno rezanje projektov. Pretekli projekti oziroma projektna prodaja je v zgodovinskih podatkih vidna kot vrhovi na letni krivulji prodaje, ki zelo odstopajo od povprečja. Planer bi v primeru, da je bila količina prodaje v lanskem letu v povprečju 10 in smo imeli v nekem mesecu projekt s prodajo 100, naredil napoved, ki bi imela tudi v tem mesecu vrednost okrog 10. Po potrebi pa se bi odločil tudi, ali bo v določenem mesecu spet pričakoval projekt na istem izdelku. Splošne statistične metode bi v takem primeru projekt vsaj deloma preslikale v prihodnost avtomatično. Zato smo v algoritem vgradili logično mejo, ki podatke, ki jo presežejo, izloči iz izračuna napovedi. Na ta način dobimo krivuljo napovedi, ki je veliko bolj sploščena. Tak način obravnave projektne prodaje je seveda specifičen za podjetje Danfoss in vsekakor ni nujno pravilen v vseh situacijah. Naši izdelki, kot so na primer regulacijski ventili in termostati v sistemih ogrevanja, se prodajajo v določenih velikih projektih

modernizacij obstoječih stavb ali pa v novogradnjah, le-te se ne ponavljajo, zato nima smisla prenašati projektov tudi v napoved prihodnosti. Kot primer lahko navedemo projekt modernizacije ogrevalnega sistema v Moskvi leta 2010, ki ga sedaj nekaj desetletij ne bodo. Pri takšnem načinu obravnave projektne prodaje pridemo do sledečega problema. V našem primeru je okoli 15 % celotne prodaje projektne. Tako je naša izračunana napoved brez upravljanja z izjemami prenizka glede na končni rezultat za okoli 15 %. Vendar moramo vedeti, da napoved predstavlja samo redno prodajo in da je to potrebno v procesu napovedovanja upoštevati. Problema smo se lotili tako, da smo planerju omogočili ročno dodajanje „izrednih“ vrednosti k že izračunani napovedi. Poleg tega smo v proces izdelave napovedi dodali upravljanje z izjemami, ki zahteva razmislek prodajnika in planerja o tem, kdaj in na katerih izdelkih bi lahko realizirali “manjkajočo” prodajo. Algoritem torej izračuna napoved za redno prodajo, čemur planer nato doda vrednost projektne prodaje in drugih izjem.



Slika 3.3: Prikaz glajenja projektov na določenem izdelku.

Z vključitvijo statističnih modelov in odločitvene logike planerjev v algoritem napovedovanja povpraševanja smo proces napovedovanja avtomatizirali. S takšno avtomatizacijo smo prešli iz stopnje, kjer je moral planer ročno izdelati celotno napoved, do stopnje, kjer mora planer obravnavati samo izjeme. Planer v osnovi obravnava dve glavni vrsti izjem. Projektno prodajo in kritične



Slika 3.4: Prikaz ročnega popravka na nivoju izdelka.

izdelke. Pri projektni prodaji planer izhaja iz avtomatsko generirane napovedi redne prodaje, kateri doda vrednost projektne prodaje. V tem primeru je nje-gova naloga identifikacija projektov in primernih izdelkov, kjer mora ugotoviti, v katerem obdobju se bodo pojavili in kakšna bo njihova vrednost.

Drugo izjemo predstavljajo tako imenovani „kritični izdelki“. Kritični izdelki so izdelki katerih MAPE (povprečna absolutna napaka v odstotkih) je večja od 90 %. Meja, nad katero so izdelki označeni kot kritični, lahko uporabniki spreminjajo v okviru tako imenovanih globalnih spremenljivk, ki so na voljo v sistemu. Globalne spremenljivke so podrobno opisane v poglavju 4.1.5. Napovedi pri izdelkih, ki ne presegajo te meje, se ne analizirajo, razen v primeru, da je planerju izrecno naročeno, naj pregleda določeno napoved. Razlog za tako visoko mejo je v zmožnostih planerja. Pregled vseh napovedi bi enostavno predstavljal prevelik zalogaj za enega planerja. En planer lahko namreč kakovostno pregleda med 200 in 300 napovedi na mesec - to pomeni, da razišče ozadje prodaje in poišče informacije pri prodajnikih, ko so le-te potrebne za pravilno napoved. Tukaj smo izhajali iz načela 80/20, torej da z 20 % vloženega dela naredimo 80 % razlike. Tako odpravimo največje napake.

Rezultat napovedi povpraševanja so količine po posameznih izdelkih za naslednjih 12 do 24 mesecev. Napoved povpraševanja se nato kot plan količine prodaje v centralnem skladišču vnese v sistem SAP. Sistem SAP nato izračuna potrebe po kapacitetah ter repromaterialih za posamezna časovna obdobja


glede na stanje obstoječih zalog, naročil in plana prodaje. S pomočjo sistema SAP je možno preveriti tudi, ali je glede na kapacitete proizvodnje možno izvesti napoved. V primeru, da napovedi ni možno izvesti, je obveščen planer, ki mora v sodelovanju s prodajniki poiskati nadomestno rešitev in napoved.

Z implementacijo sistema za napovedovanje smo, kot že omenjeno, prešli iz ročnega izdelovanja celotne napovedi na upravljanje z izjemami. V preteklosti smo potrebovali 4 planerje, ki so bili zadolženi za izdelavo napovedi. Sedaj lahko 1 planer obravnava vse izjeme. Kljub zmanjšanju števila planerjev smo izboljšali natančnost napovedi. Razlog za to je v tem, da smo zmanjšali področje napovedi, na katerega lahko vpliva planer – v določenih primerih se namreč na podlagi statističnih podatkov izkaže, da planer naredi večjo napako kot čisti avtomatizem, do česar lahko pride v primeru neizkušenega planerja oziroma napačne presoje. Planer sicer še vedno lahko naredi napako, vendar je ta sedaj omejena večinoma le na projektni del napovedi.

3.3 Uporabna vrednost napovedi v različnih okoliščinah

Pri izdelavi napovedi je pomembno razumevanje prodaje oziroma njenih oblik in vzorcev. V podjetju Danfoss lahko opazimo več oblik prodaje. Glede na gibanja prodaje pri posameznih izdelkih lahko le-te v splošnem razdelimo v tri skupine. Te skupine sovpadajo z ABC klasifikacijo izdelkov.

3.3.1 Izdelki tipa A



Slika 3.5: Prikaz povprečne količine prodaje izdelkov tipa A za dve različni družini izdelkov.

Obnašanje prodaje se pri tej skupini kaže z izrazito sezonskostjo. Tako imamo v začetku leta nizko sezono, ki se začne dvigovati v poletnih mesecih, ko nastopi visoka sezona. Visoka sezona se zaključi proti koncu leta in tako je vsako leto - gibanje je povezano z gradnjo in prenovo ogrevalnih sistemov, ki se dogajajo v toplih poletnih mesecih, ko ni potrebe po ogrevanju. Do stabilne sezonskosti pride tudi zaradi velikega števila kupcev na različnih trgih, saj so tako manj opazne značilnosti posameznih trgov. Posledica tega je, da pri tej obliki prodaje dobro delujejo standardne statistične metode.

Pomen napovedi

Izdelki v tej skupini predstavljajo okoli 80 % celotne količine prodaje. Zaradi tega se je potrebno pri implementaciji algoritma za napovedovanje povpraševanja osredotočiti predvsem na te izdelke. Napoved je pri tej skupini pomembna za planiranje zalog, kapacitet in nabave.

- **Zaloge**

Na podlagi napovedi povpraševanja se izračuna potrebna količina zalog. V primeru, da izdelkov nimamo na zalogi, jih ne moremo ponuditi kupcem. Razlog je v tem, da kupci potrebujejo določen izdelek naslednji dan, vendar če nimamo izdelka na zalogi, lahko za dostavo do kupca porabimo tudi 1 mesec, saj je potrebno izdelek najprej izdelati. Ker so ti izdelki najpomembnejši za poslovanje Danfossa, morajo biti vedno na voljo.


- **Kapacitete**

Pri teh izdelkih imamo opravka z velikimi količinami izdelkov, kar posledično predstavlja veliko število delovnih ur. V primeru napačne napovedi na teh izdelkih se lahko zgodi, da imamo v določenem obdobju premalo zaposlenih za realizacijo naročil.

- **Nabava**

Prav tako potrebujemo pri teh izdelkih veliko količino materialov, ki jih moramo naročiti pri dobaviteljih. V primeru napačne napovedi se lahko zgodi, da dobavitelji ne bodo mogli dobaviti zadostno količino materialov. Nekateri materiali imajo lahko dobavni rok tudi 6 mesecev, torej moramo že pol leta prej vedeti, kdaj in koliko takih materialov bomo potrebovali. Pri nabavi je pomembno tudi to, da nam dobavitelj na podlagi napovedi pove, ali nam lahko zagotovi potrebno količino materialov.

3.3.2 Izdelki tipa B



Slika 3.6: Prikaz povprečne količine prodaje izdelkov tipa B za dve različni družini izdelkov.

Obnašanje prodaje se pri tej skupini prav tako kaže z izrazito sezonskostjo, vendar je že opaziti odklone. Sezonskost je lahko tudi obratna od običajne. Tukaj je opazen vpliv manjšega števila kupcev (1 do 2 velika kupca in veliko nestalnih kupcev). Sezonskost je tako bolj odvisna od posameznega trga.

Pomen napovedi


Izdelki v tej skupini predstavljajo približno 15 % celotne prodaje. Napoved je pri tej skupini pomembna predvsem za planiranje zalog.

- **Zaloge**

Tudi pri majhnih količinah je še vedno pomembno vedeti, koliko končnih izdelkov potrebujemo, da lahko zagotovimo dobavljivost na kratek rok.

Manjši poudarek je na kapacitetah in nabavi. Izdelki v tej skupini imajo namreč večino materialov podobnih kot izdelki tipa A, tako je recimo samo kakšen element izdelka drugačen, kar lahko zagotovimo s planom zalog. Poleg tega lahko odstopanja manjših količin kompenzirajo dobavitelji brez velikih zaostankov.

3.3.3 Izdelki tipa C



Slika 3.7: Prikaz povprečne količine prodaje izdelkov tipa C za dve različni družini izdelkov.

Izdelke v tej skupini lahko razdelimo v tri podskupine.

Prva skupina predstavlja izdelke, ki zunaj visoke sezone skoraj nimajo prodaje. Izdelki se prodajajo v običajnih projektih (so del standardne specifikacije).

Druga skupina predstavlja izdelke, ki nimajo sezonske komponente, saj gre predvsem za unikatne izdelke, ki se prodajo za določene specifične projekte. Prodaja takih izdelkov se ne ponavlja vsako leto.

Tretja skupina predstavlja izdelke, ki nimajo prodaje. Podjetje Danfoss ima veliko izdelkov, za katere obstaja samo načrt in se izdelajo samo v primeru posebnega naročila. Gre za različne variacije nekega standardnega izdelka.

Pri vseh treh tipih izdelkov statistične metode ne dajejo zadovoljivih rezultatov. Napoved, izračunana z uporabo standardnih statističnih metod, vsebuje pri tej obliki prodaje ničle ali pa daje podcenjeno oceno. Zaradi tega smo za to skupino izdelkov izdelali posebno metodo, ki je opisana v poglavju 4.2.6.

Pomen napovedi


Izdelki v tej skupini predstavljajo približno 5 % celotne prodaje. Napoved je pri tej skupini pomembna predvsem za planiranje nabave posebnih materialov.

- **Nabava**

Pri tej skupini lahko v izdelkih nastopajo posebni materiali, ki se ne uporabljajo pri izdelkih tipa A in B. Zaradi tega je potrebno dobaviteljem sporočiti, koliko in kdaj jih potrebujemo.

Pri tej skupini so zaloge in kapacitete relativno nepomembne. Zalog za te izdelke nimamo. Kapacitete pri tej skupini predstavljajo samo 5 %, poleg tega jih navadno napovemo v napačnem mesecu, saj ni pravil oziroma možnosti ugotoviti, kdaj bo prišlo do dejanske prodaje.

3.3.4 Projektna prodaja



Slika 3.8: Prikaz celotno količino prodaje izdelkov tipa A za dve različni družini izdelkov.

Projektna prodaja predstavlja dodatek k redni prodaji na posameznih izdelkih. Projekti se načeloma lahko pojavljajo do trikrat na leto za posamezen izdelek na različnih trgih in z različnimi kupci. To vrsto prodaje ne obravnava nobena metoda oziroma je celo namenoma izločena iz kalkulacij ter jo je potrebno obravnavati ročno. Način obravnavanja projektne prodaje je opisan v procesu napovedovanja prodaje [pnp].

Pomen napovedi

Projektna prodaja predstavlja 15 % celotne prodaje. Pri tej skupini so pomembne kapacitete in nabava, vendar naš sistem ne pokriva nabave, saj je problem v tem, da dokler ne vemo za projekt, ne moremo napovedati, kateri izdelek se bo prodajal v okviru projekta, hkrati se to zgodi zelo pozno in imamo posledično zelo kratek čas za dobavo, tako velikokrat ne moremo pravočasno tega vključiti v napoved. Projektna prodaja, ki jo uspemo pravočasno vključiti v napoved, predstavlja okoli 10 % celotne napovedi. Možnost nabave se preverja v ločenem procesu, kjer se preveri, ali je dobava možna v predvidenih

časovnih okvirih. Kljub temu lahko napovemo kratkoročne potrebe po kapacitetah. Dodatnih zalog v tej skupini nimamo.

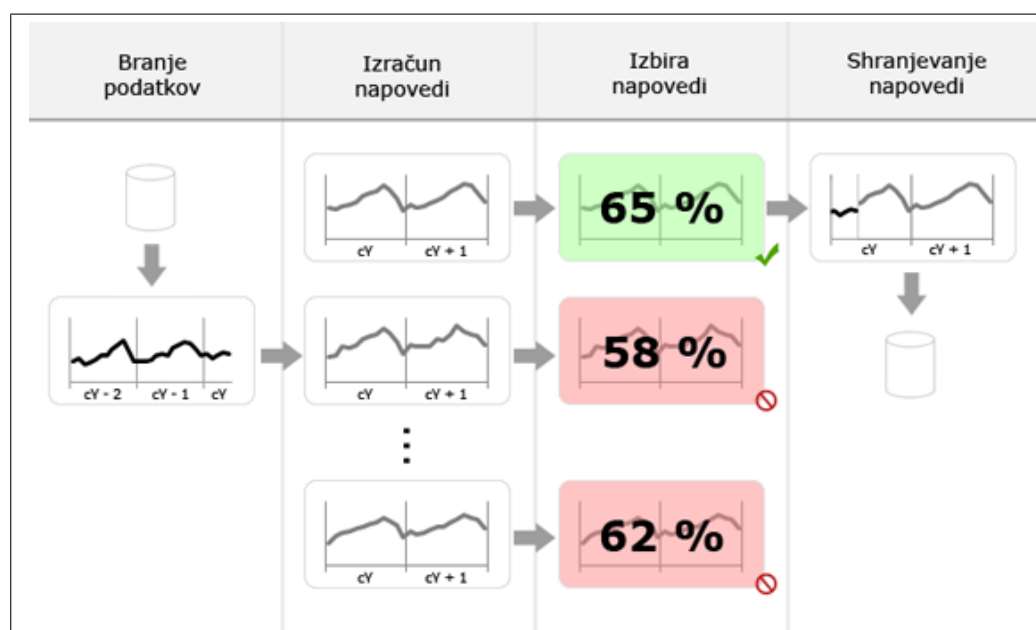
- **Kapacitete**

Pri napovedovanju kapacitet je v tem primeru pomembno, da jih napovemo vsaj 3 mesece pred potrebo. Toliko namreč znaša reakcijski čas proizvodnje za zagotavljanje kapacitet.

Pri tej skupini so zaloge in kapacitete relativno nepomembne. Zalog za te izdelke nimamo. Kapacitete pri tej skupini predstavljajo samo 5%, poleg tega jih navadno napovemo v napačnem mesecu, saj ni pravil oziroma možnosti ugotoviti, kdaj bo prišlo do dejanske prodaje.

Poglavje 4

Algoritem napovedovanja povpraševanja



Slika 4.1: Prikaz algoritma napovedovanja povpraševanja.

Osnovna naloga algoritma je izračun napovedi povpraševanja za prihodnji dve leti na podlagi zgodovinskih podatkov. Algoritem se izvaja mesečno za posamezne kombinacije statističnih skupin in trgov. Algoritem sestoji iz sledečih korakov:

1. branje vhodnih podatkov,
2. izračun statistik na izbrani statistični skupini,
3. izračun napovedi,
4. shranjevanje napovedi.

Algoritem se začne z branjem vhodnih podatkov iz baze podatkov. Vhodne podatke algoritma predstavljajo: izdelki, zgodovinski podatki, ročno podana sezonskost, prodajne informacije, ročni popravki (na nivoju družine izdelkov ter izdelka), globalne spremenljivke.

Algoritem pred izračunom napovedi za posamezen izdelek na posameznem trgu izračuna statistike na izbrani statistični skupini, ki se nato v določenih primerih uporabijo pri izračunu napovedi za posamezne izdelke. Izračunane statistike so: vsota prodaje zadnjega leta za celotno statistično skupino (uporabi se drseče leto), vsota predvidene prodaje izdelkov z oznako NIIC in sezonskost celotne statistične skupine. Pomen oznake NIIC je predstavljen v poglavju 4.1.1.

Sledi izračun napovedi. Algoritem izračuna napoved za vsak posamezen izdelek posebej. Izračun napovedi za posamezen izdelek sestoji iz sledečih korakov.

- a. Preverimo, ali gre za izdelek s pretrgano časovno vrsto. V tem primeru izračunamo napoved po modelu pretrgane časovne vrste in nadaljujemo na koraku d. Pretrgane časovne vrste so podrobno predstavljene v poglavju [pcvrst].
- b. Izračunamo napoved po različnih statističnih modelih za trenutno in naslednje leto. V primeru, da pri določenem izdelku uporabimo letni ročni popravek na nivoju izdelka, izračunamo napoved po modelu Od zgoraj navzdol V1 in nadaljujemo na koraku d.
- c. Za vsak model izračunamo skupno napako v zadnjih treh mesecih. Izberemo napoved, ki ima najmanjšo napako.
- d. Izbrani napovedi prištejemo mesečni ročni popravek na nivoju izdelka.

Napaka se izračuna z uporabo enačbe:

$$Error = \sum_{m=M_C-3}^{m=M_C-1} |R_q(m) - F_q(m)|, \quad (4.1)$$

kjer M_C predstavlja trenutni mesec („Current month“).

Na koncu algoritma shrani izbrano napoved v bazo podatkov. Nova napoved se shrani v bazo podatkov za naslednji in prihodnje mesece. Napoved tekočega in preteklih mesecev ostane nespremenjena.

V zgoraj opisanem algoritmu lahko uporabnik tudi ročno določi model, po katerem se izračuna napoved za določen izdelek.

4.1 Vhodni podatki

4.1.1 Seznam izdelkov

Napoved prodaje se izračuna za vse izdelke, ki pripadajo izbrani statistični skupini in izbranemu trgu. Podatki o izdelkih so shranjeni v dveh tabelah, in sicer Item ter Item Details. Tabeli sta povezani preko atributa Item.

Item		Item Details	
PK	Item	PK, FK	Item
FK	Stat	PK, FK	Country
	Product Status		Market Price
	Log ABC		NIIC

Tabela 4.1: Prikaz tabel Item in Item Details.

Tabela Item vsebuje attribute, ki so neodvisni od trga. Mednje spadata:

- **Product Status**

Product status označuje stopnjo v življenjskem ciklu izdelka. Vrednost "XI" predstavlja nove izdelke. Vrednost "XI" ostane prvih 12 mesecev nespremenjena. Pri teh izdelkih se v modelu od zgoraj navzdol uporabi ročno določena sezonskost, ki je drugačna pri novih izdelkih.

- **Log ABC („Logistical ABC“)**

Log ABC predstavlja logistično ABC klasifikacijo izdelkov in je skupna vsem izdelkom na vseh trgih. Posamezne vrednosti označujejo, kako pogosto se prodajajo določeni izdelki. Izdelki z oznako A in B se prodajajo pogosto, izdelki z oznako C redko. Algoritma pri vrednostih A in B posodobi napoved od meseca $M_c + 1$ naprej in pri vrednosti C od meseca $M_c + 3$ naprej. Pri izdelkih z oznako C zaradi logističnih razlogov namreč ni zaželeno, da se napoved spreminja v bližnji prihodnosti. Zgoraj uporabljena kratica M_c predstavlja trenutni mesec („Current month“).

Tabela Item Details vsebuje attribute, ki so odvisni od trga. Mednje spadata:

- **NIIC**

NIIC oziroma „Not Included In Calculation“ predstavlja oznako, ki določa, ali so izdelki vključeni v izračun statistik na nivoju celotne statistične skupine, kot sta recimo sezonskost in celotna vrednost prodaje. Pri izdelkih z oznako NIIC se v modelu od zgoraj navzdol uporabi ročno določena sezonskost. Pomen označevanja izdelkov z oznako NIIC je podrobneje opisan v okviru poglavja 4.2.2.

- **Market Price**

Market Price predstavlja povprečno ceno izdelka na določenem trgu. Izračuna se na podlagi zadnjih 3, 6, 12 oziroma 24 mesecev glede na razpoložljive podatke o pretekli prodaji. V algoritmu se upodablja pri pretvorbi med vrednostmi in količinami.

4.1.2 Prodajne informacije

V algoritmu se poleg zgodovinskih podatkov uporabljajo tudi informacije, ki nam jih posredujejo prodajniki. Te informacije so shranjene v tabeli Forecast.

Forecast	
PK, FK	Stat Group
PK, FK	Country
PK	Year
	Input
	Price Diff

Tabela 4.2: Prikaz tabele Forecast.

Tabela vsebuje dva atributa, ki predstavljajta prodajne informacije:

- **Input**

Input predstavlja skupno pričakovano vrednost prodaje za določeno leto ter določeno statistično skupino (vnaša se za naslednji dve leti). V algoritmu se pri modelu Od zgoraj navzdol V1 uporablja kot osnovna vrednost, ki se nato pretvori v napoved za naslednji dve leti.

- **Price Diff („Price difference“)**

Price Diff predstavlja pričakovano spremembo v ceni za določeno leto ter določeno statistično skupino (vnaša se za naslednji dve leti). V algoritmu se skupaj z Market Price uporablja pri pretvorbi med vrednostmi in količinami.

4.1.3 Zgodovinska prodaja

Uporabljeni modeli za izračun napovedi temeljijo na analizi zgodovinskih podatkov. Algoritem pri izdelavi napovedi analizira zgodovinske podatke, ki segajo dve leti v preteklost.

Podatki so shranjeni v tabeli Demand Plan Realisation:

Demand Plan Realisation		Demand Plan Realisation	
PK, FK	Item	PK, FK	Item
PK, FK	Country	PK, FK	Country
PK	Year	PK	Year
	RQ Jan		RV Jan
	RQ Feb		RV Feb
	⋮		⋮
	RQ Dec		RV Dec

Tabela 4.3: Prikaz tabele Demand Plan Realisation.

Tabela vsebuje število ter dejansko vrednost prodanih količin po posameznih mesecih v določenem letu za določen izdelek na določenem trgu.

4.1.4 Ročno podana sezonskost

Pri izdelkih brez zgodovinskih podatkov, novih izdelkih in izdelkih z oznako NIIC se v modelu od zgoraj navzdol za izračun napovedi uporabi ročno določena sezonskost. Ta je shranjena v tabeli Alternate Seasonality:

Alternate Seasonality	
PK, FK	Item
PK, FK	Country
PK	Year
	S Jan
	S Feb
	⋮
	S Dec

Tabela 4.4: Prikaz tabele Alternate Seasonality.

Tabela vsebuje ročno določeno sezonskost po posameznih mesecih v določenem letu za določeno statistično skupino na določenem trgu. Sezonskost je podrobneje opisana v poglavju 4.2.1.

4.1.5 Globalne spremenljivke

Globalne spremenljivke predstavljajo del algoritma napovedovanja povpraševanja, ki ga lahko prilagajajo uporabniki in s tem spreminjajo izračun napovedi.

V algoritmu nastopajo sledeče globalne spremenljivke:

- **TAPEmax** („Total Absolute Percentage Error Max“)

Predstavlja največjo dovoljeno napako TAPE (skupna absolutna napaka v odstotkih), nad katero je potrebno napoved na nivoju izdelka popraviti. Privzeta vrednost je 0,5 (50% napaka).

- **ProjF** („Project Factor“)

Predstavlja faktor, s katerim pomnožimo letno povprečje ter tako dobimo mejo, nad katero zgodovinsko prodajo štejemo kot projektno prodajo. Projektna prodaja ni vključena v izračunih. Potrebno je omeniti, da lahko projekte preslikamo v prihodnost, v kolikor nastavimo zelo visoko mejo. Privzeta vrednost je 3 (trikratnik povprečja).

- **ModF** („Modification Factor“)

Predstavlja faktor, ki določa, koliko se napoved popravi navzgor v primeru, da je bila prodaja v zadnjih treh mesecih večja od napovedane. Privzeta vrednost je 0,03 (3% povečanje).

- **ModFNegative („Modification Factor Negative“)**

Predstavlja faktor, ki določa koliko se napoved popravi navzdol v primeru, da je bila prodaja v zadnjih treh mesecih manjša od napovedane. Privzeta vrednost je -0,12 (12% zmanjšanje).

- **Critical Code Threshold**

Določa maksimalno napako MAPE, nad katero napoved označimo kot kritično. Uporablja se kot indikator, ki označuje izdelke s slabo napovedjo. Indikator planer uporablja pri pregledovanju izračunanih napovedi. Privzeta vrednost je 0,9 (90% napaka).

4.1.6 Ročni popravki na nivoju družine izdelkov

Družino izdelkov lahko obravnavamo kot celoto, saj lahko pri izdelkih, ki pripadajo enaki družini izdelkov, opazimo podoben trend ter sezonskost. Iz te predpostavke izhajajo ročni popravki na nivoju družine izdelkov.

Ročni popravki na nivoju družine izdelkov služijo kot orodje za popravljanje napovedi določene družine izdelkov ter tako prihranijo čas s popravljanjem napovedi na posameznih izdelkih. Sistem avtomatično izračuna, katere izdelke je potrebno bolj popraviti.

V algoritmu so uporabljeni ročni popravek na letnem nivoju, ročni popravek za posamezen mesec ter maksimalna dovoljena rast na posameznem izdelku. V kolikor rast, povečana za ročni popravek, preseže maksimalno dovoljeno rast, je rast enaka vrednosti maksimalne dovoljene rasti.

Ročni popravki so določeni za posamezno družino izdelkov na posameznem trgu ter za določeno leto in so shranjeni v tabeli Budget Group Correction:

Budget Group Correction	
PK, FK	Budget Group
PK, FK	Country
PK	Year
	Max Growth
	CF Yearly
	CF Jan
	CF Feb
	⋮
	CF Dec

Tabela 4.5: Prikaz tabele Budget Group Corrections.

Ročni popravki se v algoritmu uporabljajo kot faktorji, ki napoved popravijo navzgor oziroma navzdol. Pri tem je potrebno poudariti, da recimo vrednost 0,2 ne pomeni dejansko 20% povišanje napovedi, ampak je povišanje odvisno od sestave družine izdelkov oziroma metod, po katerih so bile izračunane napovedi za posamezne izdelke v družini. Napoved posameznih izdelkov se lahko izračunajo po različnih metodah, od katerih nekatere upoštevajo ročne popravke aditivno, druge multiplikativno, poleg tega se lahko v družini pojavijo tudi izdelki z prekinjajočo časovno serijo, ki ne upošteva mesečnih ročnih popravkov.

4.1.7 Ročni popravki na nivoju izdelka

V algoritmu smo uporabili dva načina ročnih popravkov na nivoju izdelka, in sicer letni ter mesečni.

Letni

Letni ročni popravek (*MYearly*) je v osnovi uporabljen na način, da zaobide avtomatsko izračunano oceno prodajnih količin za naslednje leto. Torej, v primeru da je ročni popravek vnešen za določeno leto za določen izdelek, se ta količina razporedi po posameznih mesecih z uporabo sezonske komponente in ostalih manipulacij. Poleg tega se letni ročni popravek uporablja še pri izračunu skupne vrednosti izdelkov z oznako NIIC, kot osnova za izračun vrednosti posameznega izdelka.

Mesečni

Mesečni ročni popravek se uporablja kot dodatek k avtomatsko izračunani napovedi. Avtomatsko izračunana napoved namreč predstavlja redno prodajo, kateri je potrebno dodati projektno prodajo. Mesečni ročni popravek se enostavno prišteje k napovedi.


Ročni popravki so določeni za posamezen izdelek na posameznem trgu ter za določeno leto in so shranjeni v tabeli Demand Plan:

Demand Plan	
PK, FK	Item
PK, FK	Country
PK	Year
	M Yearly
	M Jan
	M Feb
	⋮
	M Dec

Tabela 4.6: Prikaz tabele Demand Plan.

4.2 Modeli napovedovanja

Podatke, ki jih preberemo iz baze podatkov, shranimo v obliki podatkovnih polj, preko katerih so nato dostopni v algoritmu. Podatki so v bazi podatkov organizirani tako, da so vrednosti za posamezno leto shranjene v vrsticah, vrednosti za posamezne mesece pa v stolpcih. Ker algoritem operira vedno z zgodovinskimi podatki zadnjih dveh let ter izračunava napoved za trenutno in naslednje leto, podatke za posamezna leta in mesece shranimo v eno podatkovno polje za posamezen tip podatkov. Podatkovno polje je prikazano na sliki 4.2, kjer oznaka Y_c predstavlja trenutno leto („Current year“) in M_c trenutni mesec („Current month“).



Slika 4.2: Prikaz podatkovnega polja.

Pri delu s podatkovnim poljem uporabljamo dve funkciji:

$$RelY(m_r) \text{ in} \quad (4.2)$$

$$RelM(m, y_r). \quad (4.3)$$

Funkcija 4.2 je namenjena preslikavi med relativnim mesecem in relativnim letom. Kot primer lahko vzamemo 1. mesec trenutnega leta oziroma 24. relativni mesec. Funkcija 4.2 bi tako pri klicu $RelY(24)$, vrnila vrednost 2, kar predstavlja relativno vrednost trenutnega leta.

Funkcija 4.2 je namenjena preslikavi med mesecem in relativnim mesecem. Kot primer lahko prav tako vzamemo, 1. mesec trenutnega leta. Funkcija 4.2 bi tako pri klicu $RelY(1, 2)$, vrnila vrednost 24, kar predstavlja relativno vrednost trenutnega meseca.

V nadaljevanju so opisani različni modeli napovedovanja.

4.2.1 Od spodaj navzgor V1

Pri izračunu napovedi povpraševanja po metodi od spodaj navzgor izhajamo iz podrobnih zgodovinskih podatkov o prodanih količinah in trendu le teh. Za izračun napovedi potrebujemo število prodanih količin po mesecih za trenutno ter za pretekli dve leti. Poleg podatkov o prodaji pri metodi potrebujemo še podatke o zadnji napovedi, torej napovedano število prodajnih količin po mesecih.

Osnovna enačba za izračun napovedi je sledeča:

$$F_q(m) = EstAvg_y(RelY(m)) * (S(m) + EC(m) + CF_m(m)), \quad (4.4)$$

kjer:

- $F_q(m)$ predstavlja napoved za mesec m ,
- $EstAvg_y(y)$ ocenjeno povprečno količino za leto y (trend zgodovinskih podatkov projiciran v prihodnost),
- $S(m)$ sezonsko vrednost za mesec m ,
- $EC(m)$ popravek napake za mesec m in
- CF_m ročni popravek napovedi za mesec m (določen na nivoju družine izdelkov).

V enačbi 4.2.1 vrednosti v oklepaju predstavljajo manipulacije ocenjene povprečne količine. Torej v primeru, da nimamo popravka napake ter ročnega popravka napovedi in je sezonska vrednost za obravnavan mesec enaka ena, je vrednost napovedi enaka ocenjeni povprečni količini, ki je že povečana oziroma zmanjšana za vpliv trenda.

Napoved povpraševanja se z uporabo enačbe 4.2.1 izračuna za vse mesece v tekočem in naslednjem letu ter predstavlja napovedano število prodajnih količin po posameznih mesecih.

Ocenjena povprečna količina in trend

Ocenjena povprečna količina

Za izračun napovedi povpraševanja potrebujemo povprečno količino za preteklo leto, ki predstavlja osnovno vrednost za nadaljnje manipulacije. Povprečno količino nato popravimo za vpliv trenda. Tako dobljeno vrednost imenujemo ocenjena povprečna količina trenutnega leta.

Ocenjeno povprečno količino izračunamo za trenutno in naslednje leto na sledeč način:

$$EstAvg_y(Y_c) = Growth_{Mod}(Y_c) * CorrAvg_y(Y_c - 1), \quad (4.5)$$

$$EstAvg_y(Y_c + 1) = Growth_{Mod}(Y_c + 1) * EstAvg_y(Y_c), \quad (4.6)$$

kjer Y_c predstavlja trenutno leto („Current year“), $Growth_{mod}(y)$ popravljen trend za izbrano leto in $CorrAvg_y(y)$ popravljen povprečno količino za izbrano leto.

Povprečne vrednosti

Pri izračunu ocenjene povprečne količine za posamezno leto potrebujemo tri povprečne vrednosti. Popravljeni povprečni količini za zadnji dve leti ($CorrAvg_y(y)$) in povprečno količino zadnjih treh mesecev (Avg_{l3m}). Pri izračunu povprečnih vrednosti potrebujemo število prodanih količin v trenutnem letu in v zadnjih dveh letih. Pri mesecih, za katere nimamo podatka in jih potrebujemo (pri $Y_c + 1$) za število prodanih količin uporabimo napovedano število prodajnih količin iz zadnje izračunane napovedi.

Osnovni enačbi za izračun povprečnih vrednosti so:

$$\begin{aligned} CorrAvg_y(y) = \frac{1}{10} * ((\sum_{m=RelM(1,y)}^{m=RelM(12,y)} R_q(m)) \\ - \min(R_q(RelM(1, y)), R_q(RelM(2, y)) \dots R_q(RelM(12, y))) \\ - \max(R_q(RelM(1, y)), R_q(RelM(2, y)) \dots R_q(RelM(12, y))))), \end{aligned} \quad (4.7)$$

$$Avg_{l3m} = \frac{1}{3} * ((\sum_{m=M_c-3}^{m=M_c-1} R_q(m)) - Proj_{Max}), \quad (4.8)$$

kjer M_c predstavlja trenutni mesec („Current month“), $Proj_{Max}$ največjo vrednost, ki je v izbranem obdobju preseгла mejo, nad katero prodajo štejemo

kot projektno prodajo, $R_q(m)$ število prodanih količin v določenem mesecu. Število prodanih količin v trenutnem in prihodnjih mesecih dejansko predstavlja napovedano število prodanih količin iz zadnje izračunane napovedi. Na ta način lahko izračunamo popravljeno povprečno količino za prihodnje leto. Pri izračunu povprečne količine zadnjih treh mesecev se $Proj_{Max}$ odšteje samo v primeru, ko je vsaj ena vrednost preseгла mejo, nad katero se prodaja šteje kot projektna prodaja. Meja, nad katero prodajo štejejo kot projektno prodajo določimo na sledeč način:

$$R_q(m) \geq Avg_{ytd} * ProjF, \quad (4.9)$$

kjer $R_q(m)$ predstavlja število prodanih količin v določenem mesecu, $ProjF$ globalno spremenljivko in Avg_{ytd} povprečno število prodanih količin v trenutnem letu, ki ga izračunamo na sledeč način:

$$Avg_{ytd} = \frac{1}{M_c - 1} * \sum_{m=MRM(1, Y_c)}^{m=M_c-1} R_q(m). \quad (4.10)$$

Povprečne vrednosti so popravljene z namenom preprečiti, da bi projektna prodaja vplivala na določanje trenda.

Trend

Osnovni enačbi za izračun trenda sta:

$$Growth(Y_c) = \frac{CorrAvg_y(Y_c - 1)}{CorrAvg_y(Y_c - 2)}, \quad (4.11)$$

$$Growth(Y_c + 1) = \sqrt[4]{\frac{EstAvg_y(Y_c)}{CorrAvg_y(Y_c)}}, \quad (4.12)$$

kjer $Growth(Y_c)$ predstavlja rast oziroma padec glede na zadnji dve leti in $Growth(Y_c + 1)$ rast oziroma padec v trenutnem letu v primerjavi z ocenjeno povprečno vrednostjo v trenutnem letu. V primeru, da je rast oziroma padec v posameznem letu večja od 25% v primerjavi s povprečjem zadnjih dveh let:

$$\frac{|CorrAvg_y(y) - CorrAvg_y(y)|}{\frac{CorrAvg_y(y) + CorrAvg_y(y)}{2}} > 0,25 \quad (4.13)$$

se trend zgladi z uporabo korena:

$$Growth(y) = \sqrt{Growth(y)}, \quad (4.14)$$

kar prepreči prevelika nihanja v trendu. Rast je dodatno omejena z globalno spremenljivko $MaxGrowth$. V primeru, da je rast večja od dovoljene vrednosti je trend enak maksimalni dovoljeni vrednosti:

$$Growth(y) = MaxGrowth(y) + 1. \quad (4.15)$$

Popravljen trend, ki nastopa v enačbi 4.2.1 in 4.2.1, dobimo tako da trendu prištejemo letni ročni popravek na nivoju družine izdelkov:

$$Growth_{Mod}(y) = Growth(y) + CF_Y(y). \quad (4.16)$$

Izjeme

Pri izračunu trenda za trenutno leto obstajata dve izjemi.

V primeru padca v zadnjih dveh letih in rasti v zadnjih treh mesecih:

$$CorrAvg_y(Y_c - 2) > CorrAvg_y(Y_c - 1) \wedge CorrAvg_y(Y_c - 1) < Avg_{l3m} \quad (4.17)$$

preverimo, če je razlika med povprečjem zadnjih treh mesecev in povprečjem zadnjega leta več kot za 30 % večja od povprečne vrednosti obeh povprečij:

$$\frac{|(CorrAvg_y(Y_c - 1) - Avg_{l3m})|}{\frac{CorrAvg_y(Y_c - 1) + Avg_{l3m}}{2}} > 0,30, \quad (4.18)$$

v tem primeru se trend izračuna na sledeč način:

$$Growth(Y_c) = \frac{Avg_{l3m} + CorrAvg_y(Y_c - 1)}{CorrAvg_y(Y_c - 1)}. \quad (4.19)$$

Na drugi strani imamo obrnjen primer, kjer imamo rast v zadnjih dveh letih in padec v zadnjih treh mesecih:

$$CorrAvg_y(Y_c - 2) < CorrAvg_y(Y_c - 1) \wedge CorrAvg_y(Y_c - 1) > Avg_{l3m}. \quad (4.20)$$

Trend se izračuna na enak način kot pri prvi izjemi.

Izjemi se uporabljata v primeru, ko podatki zadnjih treh mesecev kažejo drugačne sliko kot podatki zadnjih dveh let. Na ta način upoštevamo zadnje podatke, ki so nam na voljo, in preprečimo paradoks, da bi zmanjševali napoved, ko prodaja raste, in obratno.

Sezonskost

Sezonskost predstavlja nihanja okoli ocenjene povprečne količine, do katerih pride zaradi različnega obsega povpraševanja v različnih obdobjih leta. Osnovne enačbe za izračun sezonskih vrednosti posameznih mesecev so sledeče:

$$S(m) = \sqrt{\frac{S_A(m) + S_B(m)}{2}}, \quad (4.21)$$

$$S_A(m) = \frac{R_q(m-12)}{\text{MovingAvg}_y(m, 1)}, \quad (4.22)$$

$$S_B(m) = \frac{R_q(m-24)}{\text{MovingAvg}_y(m, 2)}, \quad (4.23)$$

$$\text{MovingAvg}_y(m, \text{past}) = \frac{1}{n} * \sum_{i=m-12*\text{past}}^{i=m-12*(\text{past}-1)} R_q(i), \quad (4.24)$$

kjer $R_q(i)$ predstavlja število prodanih količin v mesecu i . Sezonska vrednost določenega meseca predstavlja odmik nad oziroma pod ocenjeno povprečno količino, kjer vrednost ena pomeni, da se ocenjena povprečna količina ne spremeni. V enačbi 4.2.1, je koren uporabljen kot način glajenja, s čimer preprečimo prevelike odmik od povprečne količine, do katerih pride v primeru projektne prodaje. Da se bo letna količina z uporabo sezonskih vrednosti enakomerno porazdelila med dvanajst mesecev mora biti vsota sezonskih vrednosti posameznih mesecev v posameznem letu enaka 12. Zaradi uporabe korena pri glajenju lahko pride do tega, da dobimo vrednost manjšo od 12. To moramo upoštevati in skladno s tem popraviti sezonske vrednosti posameznih mesecev. Posamezne sezonske vrednosti popravimo tako, da jim odštejemo oziroma prištejemo sorazmeren delež razlike do vrednosti 12:

$$S(m) = S(m) - \frac{(\sum_{m=\text{RelM}(1, \text{RelY}(m))}^{m=\text{RelM}(12, \text{RelY}(m))} S(m)) - 12}{12}. \quad (4.25)$$

Popravek sezonskih vrednosti izvedemo za vsako leto napovedi posebej.

Popravek napake

Pri napovedovanju povpraševanja prihaja do razlik med dejanskim in napovedanim številom prodajnih količin. Za preteklo obdobje lahko to razliko oziroma napako izračunamo in uporabimo za izboljšanje napovedovanja povpraševanja za prihodnja obdobja. Popravek napake izračunamo za trenutni mesec in ga

uporabimo pri izračunu napovedi za prihodnje tri mesece. Pri izračunu napovedi za ostale mesece upoštevamo, da je popravek napake enak nič. Za prihodnje tri mesece se izračunani popravek napake uporabi na sledeči način:

$$EC_{U_{sed}}(M_c + 1) = EC, \quad (4.26)$$

$$EC_{U_{sed}}(M_c + 2) = 0,66 * EC, \quad (4.27)$$

$$EC_{U_{sed}}(M_c + 3) = 0,33 * EC, \quad (4.28)$$

kjer EC predstavlja izračunan popravek napake v trenutnem mesecu. Spremenljivka $EC_{U_{sed}}(m)$ je uporabljena v enačbi 4.2.1, kot spremenljivka $EC(m)$.

Za izračun popravka napake za trenutni mesec moramo najprej izračunati napako $TAPE$ (skupna absolutna odstotna napaka) in MPE (povprečna odstotna napaka) za obdobje preteklih treh mesecev. Za izračun uporabimo enačbi:

$$TAPE = \sum_{m=M_c-3}^{m=M_c-1} \frac{|R_q(m) - F_q(m)|}{R_q(m)}, \quad (4.29)$$

$$MPE = \frac{1}{3} * \sum_{m=M_c-3}^{m=M_c-1} \frac{R_q(m) - F_q(m)}{R_q(m)}, \quad (4.30)$$

kjer $R(m)$ predstavlja število prodanih količin v mesecu m in $F(m)$ napovedano število prodajnih količin v mesecu m . Pri izračunu popravka napake preverimo, ali smo imeli v preteklem mesecu projekt. To pomeni, da smo prodali količino, ki je preseгла mejo za projektno prodajo. V takem primeru ne želimo popravljati napovedi tudi v prihodnost. V primeru, da v preteklem mesecu nismo imeli projekta in da $TAPE$ preseže dovoljeno vrednost, ki je določena z globalno spremenljivko $TAPE_{max}$, pa izračunamo popravek napake. Pogoji, pri katerem izračunamo popravek napake:

$$R_q(M_c - 1) < ProjF * MovingAvg_y(M_c, 1) \quad (4.31)$$

in

$$TAPE > TAPE_{max}, \quad (4.32)$$

kjer sta $TAPE_{max}$ in $ProjF$ globalni spremenljivki.

Popravek napake izračunamo na sledeč način:

$$MPE < 0 : EC = ModF * factor, \quad (4.33)$$

$$MPE > 0 : EC = ModFNegative * factor, \quad (4.34)$$

kjer sta $ModF$ in $ModFNegative$ globalni spremenljivki, ki predstavljata količino, za katero želimo popraviti napoved navzgor oziroma navzdol. Faktor v zgornji enačbi izračunamo glede na velikost $TAPE$, na sledeč način:

Interval	Faktor
$0,8 < TAPE$	4
$0,4 \leq TAPE < 0,8$	2
$0,2 \leq TAPE < 0,4$	1
$-0,2 < TAPE < 0,2$	0
$-0,4 < TAPE \leq -0,2$	1
$-0,6 < TAPE \leq -0,4$	2
$TAPE \leq -0,6$	4

4.2.2 Od zgoraj navzdol V1

Popolnoma statistične metode imajo določene prednosti, kot so recimo objektivnost, nepristranskost in možnost izračuna napovedi za veliko število izdelkov. Vendar pa moramo za najboljše rezultate uporabiti tudi izkušnje planerjev ter dodatne informacije, ki so jim na voljo [6]. V primeru metode od zgoraj navzdol smo namesto avtomatskega izračuna na podlagi statistike planerjem omogočili, da ročno podajo pričakovano vrednost prodaje na letnem nivoju za naslednji dve leti.

Izdelki so v bazi podatkov organizirani v dva hierarhična nivoja znotraj posamezne države. Prvega predstavlja družina izdelkov in drugega variacije znotraj določenega izdelka oziroma statistična skupina.

Pri izračunu napovedi povpraševanja po metodi od zgoraj navzdol izhajamo iz ročno podane ocene vrednosti prodaje celotne statistične skupine. Za izračun napovedi potrebujemo:

- vrednost prodanih količin po mesecih za trenutno ter za pretekli dve leti za vse izdelke znotraj statistične skupine ($R_V(m)$),
- povprečno ceno izdelka v preteklem letu (MarketPrice),
- pričakovano spremembo v ceni za naslednji dve leti ($PriceDiff(y)$),
- ročno podano oceno vrednosti prodaje celotne statistične skupine za naslednji dve leti ($Input(y)$),
- ročno določene sezonske vrednosti po mesecih za naslednji dve leti na nivoju statistične skupine, ki se uporablja v izjemnih primerih ter

- predvideno število prodajnih količin za naslednji dve leti (dve vrednosti) za nove izdelke in izdelke z oznako NIIC ($MYearly(y)$)

Izračun napovedi povpraševanja se razlikuje glede na tip izdelka. Pri posameznih tipih izdelkov uporabimo sledeči enačbi:

Navadni izdelki

$$F_{Q1}(m) = \frac{Qty(ReLY(m))}{12} * S_{SG}(m) * (1 + EC(m) + CF_M(m) + CF_Y(y)), \quad (4.35)$$

$$F_{Q2}(m) = \frac{MYearly(ReLY(m))}{12} * S_{SG}(m), \quad (4.36)$$

kjer

- $F_{Q1}(m)$ predstavlja napoved za mesec m ,
- $F_{Q2}(m)$ napoved za mesec m v primeru, da ročno zaobidemo ocenjeno število prodajnih količin,
- $EC(m)$ popravek napake za mesec m ,
- $S_{SG}(m)$ sezonsko vrednost za mesec m izračunano na celotni statistični skupini,
- $CF_M(m)$ ročni popravek napovedi za mesec m ,
- $CF_Y(y)$ ročni popravek rasti za leto y in
- $Qty(y)$ ocenjeno število prodajnih količin za leto y .

Novi izdelki in izdelki z oznako NIIC

$$F_q(m) = \frac{MYearly(ReLY(m))}{12} * S_{SG}(m), \quad (4.37)$$

kjer

- $MYearly(y)$ predstavlja ocenjeno število prodajnih količin za določeno leto za naslednji dve leti.

Napoved povpraševanja se z uporabo zgoraj omenjene enačbe izračuna za vse mesece v tekočem in naslednjem letu ter predstavlja napovedano število prodajnih količin po posameznih mesecih.

Tipi izdelkov

NIIC („Not included in calculation“)

Gre za izdelke, katerih podatki zelo izstopajo v primerjavi s podatki ostalih izdelkov v statistični skupini. V statistični skupini se namreč lahko pojavijo izdelki, ki imajo prodajo desetkrat večjo od ostalih izdelkov, vendar je njihovo število v primerjavi s številom vseh izdelkov v statistični skupini zelo majhno. Če bi take izdelke uporabili pri izračunu deležev posameznih izdelkov v statistični skupini glede na skupno prodano količino, bi imeli večinski delež kljub temu, da številčno predstavljajo manjšino. Poleg tega bi izračunana sezonskost ustrezala sezonskosti te majhne skupine namesto sezonskosti večine izdelkov. Planer mora sam presoditi kateri izdelki spadajo v to kategorijo.

Novi izdelki

Izdelki z oznako „XI“ oziroma izdelki, za katere nimamo zgodovinskih podatkov, so izjema, ki zahteva, da ročno določimo prihodnjo sezonskost na podlagi nestatističnih informacij (informacije prodaje, pričakovani projekti ipd).

Navadni izdelki

Izdelki, ki imajo vse potrebne podatke za izračun napovedi.

Ocenjeno število prodajnih količin

Za izračun napovedi povpraševanja potrebujemo osnovno vrednost, ki jo nato s pomočjo sezonskih vrednosti in drugih manipulacij pretvorimo v mesečno napoved za naslednji dve leti. V primeru metode Od zgoraj navzdol V1 imamo na voljo dve ročno podani količini ($Input(y)$), ki predstavljata ocenjeno vrednost prodajnih količin za naslednji dve leti. Vrednosti sta podani na nivoju statistične skupine, torej za vse izdelke vključno z izdelki, ki imajo oznako NIIC, in sta že popravljeni za vpliv trenda. Podani vrednosti moramo najprej zmanjšati za vrednost izdelkov z oznako NIIC:

$$ReducedInput(y) = Input(y) - NIICValue(y), \quad (4.38)$$

kjer $NIICValue(y)$ predstavlja vsoto vrednosti izdelkov z oznako NIIC. Vrednost posameznega izdelka z oznako NIIC za posamezno leto dobimo tako, da pomnožimo ročno podano ocenjeno število prodajnih količin za posamezno leto ($MYearly(y)$) z njegovo vrednostjo na trgu („Market price“). Ker

izračunavamo napoved posameznega izdelka, moramo najprej izračunati kakšen delež vrednosti predstavlja določen izdelek v statistični skupini, kar storimo na sledeč način.

$$Share(x) = \frac{TotalLast12M}{Last12M(x)}, \quad (4.39)$$

$$Last12M(x) = \sum_{m=(M_c-1)-12}^{m=M_c-1} R_V(m), \quad (4.40)$$

$$TotalLas12M = \sum_{\forall x \in Statisticna\ skupina} Last12M(x), \quad (4.41)$$

kjer x predstavlja določen izdelek, M_c trenutni mesec („Current month“) in $Last12M$ drsečo vsoto mesečnih vrednosti določenega izdelka za preteklo leto. Ocenjeno število prodajnih količin nato izračunamo na sledeč način:

$$Qty(y) = Share(x) * \frac{ReducedInput(y)}{MarketPrice * (1 + PriceDiff(y))}. \quad (4.42)$$

Dobljena vrednost predstavlja osnovo za nadaljnje manipulacije. Poudariti je potrebno, da dobljena vrednost že vsebuje predviden trend.

Sezonskost

Sezonske vrednosti se izračunajo na podoben način kot pri metodi Od spodaj navzgor V1. Osnovna razlika je v tem, da pri metodi Od zgoraj navzdol V1 računamo sezonske vrednosti določene statistične skupine in ne posameznega izdelka. Preden začnemo z izračunom sezonskih vrednosti moramo izračunati vrednosti prodanih količin po mesecih za statistično skupino. To storimo tako, da seštejemo vrednosti prodanih količin posameznih izdelkov po mesecih. Pri tem moramo izločiti izdelke z oznako NIIC, saj bi v nasprotnem primeru njihovi podatki popačili sezonskost statistične skupine. Osnovne enačbe za izračun sezonskih vrednosti so sledeče:

$$S_{SG}(m) = \frac{S_A(m) + S_{AM1}(m) + S_B(m)}{3}, \quad (4.43)$$

$$S_A(m) = \frac{R_V(m-12)}{Avg_y(Y_c-1)}, \quad (4.44)$$

$$S_{AM1}(m) = \frac{R_V(m-13)}{Avg_y(Y_c-1)}, \quad (4.45)$$

$$S_{AP1}(m) = \frac{R_V(m - 11)}{Avg_y(Y_c - 1)}, \quad (4.46)$$

$$S_B(m) = \frac{R_V(m - 24)}{Avg_y(Y_c - 2)}, \quad (4.47)$$

$$Avg_y(y) = \frac{1}{n} * \sum_{m=RelM(1,y)}^{m=RelM(12,y)} R_V(m), \quad (4.48)$$

kjer Y_c predstavlja trenutno leto („Current year“) in $R_V(m)$ vrednost prodanih količin v mesecu m . Z uporabo zgoraj omenjenih enačb se sezonske vrednosti izračunajo samo za trenutno leto in se uporabijo tudi kot sezonske vrednosti za naslednje leto. Pri izračunu sezonske komponente z uporabo zgoraj omenjenih enačb obstaja nekaj izjem. V primeru, da nimamo zgodovinskih podatkov za drugo leto v preteklosti in je spremenljivka $S_B(m)$ enako nič, se namesto nje uporabi $S_{AP1}(m)$. Pri izračunu sezonskih komponent za mesec januar in december moramo ustrezno popraviti izračun letnega povprečja. Tako pri izračunu sezonske komponente za mesec januar uporabimo pri izračunu spremenljivke $S_{AM1}(m)$ povprečje drugega leta v preteklosti ($Y_c - 2$) namesto preteklega leta ($Y_c - 1$). Podobno pri izračunu sezonske komponente za mesec december uporabimo pri izračunu spremenljivke $S_{AP1}(m)$ povprečje trenutnega leta (Y_c) namesto preteklega leta ($Y_c - 1$).

Da se bo letna količina z uporabo sezonske komponente enakomerno razporedila na dvanajst mesecev mora biti vsota sezonskih vrednosti posameznih mesecev v posameznem letu enaka 12. Vendar se lahko zaradi napak pri zaozkroževanju zgodi, da dobimo vrednost manjšo od 12. To moramo upoštevati in skladno s tem popraviti sezonske vrednosti posameznih mesecev. Posamezne sezonske vrednosti popravimo tako, da jim odštejemo (oziroma prištejemo) napako:

$$S_{SG}(m) = S_{SG}(m) - \frac{(\sum_{m=RelM(1,Y_c)}^{m=RelM(12,Y_c+1)} S_{SG}(m)) - 24}{24}. \quad (4.49)$$

V primeru izračuna sezonske komponente za celotno statistično skupino lahko obravnavamo obe leti v napovedi skupaj, saj je drugo leto le kopija prvega.

4.2.3 Od spodaj navzgor V2

Metodi Od spodaj navzgor V1 in Od zgoraj navzdol V1 se v osnovi razlikujeta v načinu izračuna sezonskih vrednosti ter osnovne vrednosti. Metoda Od

spodaj navzgor V1 tako izračuna sezonske vrednosti ter osnovno vrednost na podlagi zgodovinskih podatkov enega izdelka. Metoda Od zgoraj navzdol V1 pa izračuna sezonske vrednosti na podlagi podatkov celotne statistične skupine. Osnovna vrednost je pri metodi Od zgoraj navzdol V1 podana ročno. S kombiniranjem različnih načinov izračuna posameznih vrednosti pridemo do različnih variacij osnovnih metod. Prvi dve variaciji smo že opisali in jih označili z V1. Ti variaciji predstavljata osnovni metodi.

Z zamenjavo avtomatsko izračunane ocenjene povprečne količine za leto y ($EstAvg_y(y)$) z ročno podanim ocenjenim številom prodajnih količin za leto y pridemo do druge variacije metode Od spodaj navzgor V1, kar omogoča, da izkoristimo sezonskost posameznega izdelka in dodatne informacije, ki so na voljo prodajniku.

Druga variacija metode od spodaj navzgor se izračuna na sledeč način:

$$F_q(m) = \frac{Qty(y)}{12} * S(m) * (1 + EC(m) + CF_m(m) + CF_y(y)), \quad (4.50)$$

kjer $Qty(y)$ predstavlja ocenjeno število prodajnih količin za leto y in se izračuna na način opredeljenem v metodi Od zgoraj navzdol V1, $S(m)$ pa predstavlja sezonske vrednosti, ki so izračunane na način, opredeljen v metodi Od spodaj navzgor V1.

4.2.4 Od zgoraj navzdol V2

Na podoben način kot pri drugi variaciji metode Od spodaj navzgor V1 pridemo z zamenjavo ročno podanega ocenjenega števila prodajnih količin za leto y z avtomatsko izračunano ocenjeno povprečno količino za leto y ($EstAvg_y(y)$) do druge variacije metode Od zgoraj navzdol V1. Tako lahko izkoristimo sezonskost, izračunano na celotni statistični skupini, skupaj z avtomatsko izračunano ocenjeno povprečno količino.

Druga variacija metode Od zgoraj navzdol V1 se izračuna na sledeč način:

$$F_{q1}(m) = EstAvg_y(y) * S_{SG}(m) * (1 + EC(m) + CF_m(m) + CF_y(y)), \quad (4.51)$$

kjer $EstAvg(y)$ predstavlja ocenjeno povprečno količino za leto y , izračunano na način, ki je opredeljen v metodi Od spodaj navzdol V1, $S_{SG}(m)$ pa predstavlja sezonske vrednosti, izračunane na način, ki je opredeljen v metodi Od zgoraj navzdol V1.

V primeru, da ročno zaobidemo ocenjeno število prodajnih količin, se napoved povpraševanja izračuna na enak način kot pri metodi Od zgoraj navzdol V1:

$$F_{q2}(m) = MYearly(RelY(m)) * S_{SG}(m), \quad (4.52)$$

kjer $Qty(y)$ predstavlja ocenjeno število prodajnih količin za leto y in se izračuna na način, opredeljenem v metodi Od zgoraj navzdol V1.

4.2.5 Povprečje

Metodi Od spodaj navzgor V1 in Od zgoraj navzdol V1 se poleg načina izračuna osnovnih vrednosti razlikujeta tudi v tem, da je metoda Od spodaj navzgor V1 popolnoma statistična, izračunana samo na osnovi zgodovinskih podatkov, metoda Od zgoraj navzdol V1 pa vsebuje tudi mehke oziroma notranje informacije, ki jih poznata planer in prodajnik o določenem trgu. Vsak pristop ima svoje prednosti in slabosti. Tako je recimo popolnoma statističen pristop objektivni, vendar pa ne more zaznati prihodnjih sprememb na trgu.

Z uporabo povprečja lahko združimo oba pristopa ter tako pridemo še do ene variacije osnovne metode napovedovanja prodaje:

$$F_q(m) = \frac{F_{BU}(m) + F_{TD}(m)}{2}, \quad (4.53)$$

kjer $F_{BU}(m)$ predstavlja napoved povpraševanja izračunano po metodi Od spodaj navzgor V1, $F_{TD}(m)$ pa napoved povpraševanja, izračunano po metodi Od zgoraj navzdol V1.

4.2.6 Pretrgane časovne vrste

Zgoraj opisane metode so primerne za izračunavanje napovedi povpraševanja v primeru nepretrganih časovnih vrst. V primeru pretrganih časovnih vrst te metode ne dajejo zadovoljivih rezultatov. O pretrganih časovnih vrstah govorimo takrat, kadar imamo prodajo le v nekaj mesecih različno od nič. V takem primeru daje že naivna metoda, ki predvideva, da bo napovedana prodaja v vseh prihodnjih mesecih enaka nič boljše rezultate od opisanih. Napovedovanja prodaje v primeru pretrganih časovnih serij se moramo torej lotiti na drugačen način [2].

V literaturi je mogoče zaslediti različne alternativne pristope napovedovanja povpraševanja v primeru pretrganih časovnih vrst. Tak primer je Crostonova metoda. V osnovi te metode predpostavljajo, da se vrhovi (primer, v katerem je prodaja različna od neke osnovne vrednosti, v našem primeru nič) pojavljajo v različnih časovnih intervalih in za napoved vzamejo neko povprečno vrednost zgodovinskih podatkov. Poleg tega ne izračunavajo napovedi za posamezne periode v prihodnosti, ampak izračunajo eno vrednost, ki velja za prihodnost [2]. To je lahko zadovoljivo v primeru, ko uporabljamo napoved

za boljše obvladovanje zalog, vendar v našem primeru potrebujemo tudi napoved, v katerem časovnem obdobju naj bi se povpraševanje pojavilo zaradi potreb po nabavi posebnih materialov.

V našem primeru smo pri analizi preteklih podatkov ugotovili, da se vrhovi v zaporednih letih pojavljajo v enakih kvartalnih. Tako lahko z veliko verjetnostjo napovemo, da se bo vrh v naslednjem letu pojavil v enakem kvartalu kot preteklo leto.

Preden izračunamo napoved moramo ugotoviti, ali gre pri obravnavanem izdelku za izdelek s pretrgano časovno vrsto. To lahko sklepamo v primeru, da velja vsaj eden izmed sledečih pogojev:

$$Peaks(Y_c - 1) \leq 3, \quad (4.54)$$

$$CorrAvg_y(Y_c - 1) < 3, \quad (4.55)$$

$$CorrAvg_y(Y_c - 2) < 3, \quad (4.56)$$

kjer Y_c predstavlja trenutno leto („Current year“), $Peaks(Y_c - 1)$ število vrednosti različnih od nič (vrhov) in $CorrAvg_y(y)$ popravljeno povprečno količino za določeno preteklo leto. Število 3 v prvi enačbi predstavlja število vrednosti različnih od nič (vrhov), pri katerih izdelek še obravnavamo kot izdelek s prekinjeno časovno serijo. Število 3 v drugi in tretji enačbi pa pomeni, da izdelke, ki so imeli v zadnjem oziroma predzadnjem letu prodajo manjšo od 36 količin štejemo kot izdelke z pretrgano časovno serijo. Oba faktorja sta bila določena na podlagi analize preteklih podatkov. Za izračun napovedi prodaje pri izdelkih s pretrgano časovno serijo uporabimo sledeči enačbi:

$$\begin{aligned} F_{q1}(m) = & \\ & (0,2 * R_q(m - 24) + 0,5 * R_q(m - 12) \\ & + 0,2 * R_q(m - 11) + 0,1 * R_q(m - 1)) \\ & (1 + CF_y(y)), \end{aligned} \quad (4.57)$$

$$\begin{aligned} F_{q2}(m) = & \\ & (0,4 * R_q(m - 24) + 0,5 * R_q(m - 12) \\ & + 0,5 * R_q(m - 11) + 0,4 * R_q(m - 1)) \\ & (1 + CF_y(y)), \end{aligned} \quad (4.58)$$

kjer prva enačba predstavlja navadni izračun in druga popravljene izračun. Faktorji, ki so uporabljeni v posamezni enačbi, so določeni na podlagi izkušenj planerjev.

Napovedano število prodanih količin je omejeno z vrednostjo $ProjF * CorrAvg_y(Y_c - 1)$.

V primeru, da je napovedana vrednost prodaje podcenjena glede na prodajo zadnjih dveh let, se uporabi popravljena varianta izračuna, ki izdatneje upošteva zgodovinske podatke z namenom zagotavljanja zadostnih količin v napovedi.

4.3 Natančnost napovedi


Pri opisovanju procesa napovedovanja povpraševanja smo omenili, da je ena izmed izboljšav, ki jo je prinesla implementacija novega sistema za napovedovanje, tudi večja natančnost napovedi. Večjo natančnost smo dosegli predvsem na račun avtomatizirane izdelave napovedi.

4.3 prikazuje povečanje natančnosti napovedi z uvedbo sistema za napovedovanje povpraševanja. Do leta 2008 je izdelava napovedi potekala še ročno. Sredi leta 2008 smo uvedli prvo verzijo sistema za napovedovanje in opazili prvo povečanje natančnosti. Ob uporabi sistema smo opazili nadaljnje možnosti za izboljšave in tako sredi leta 2009 uvedli naslednjo verzijo sistema. Ena izmed izboljšav, ki smo jih vključili v drugo verzijo sistema je recimo poseben način obravnave projektne prodaje, ki smo ga tudi opisali v diplomskem delu. S stalnimi izboljšavami smo sedaj povečali natančnost napovedi za 9-odstotnih točk glede na natančnost napovedi pred uporabo sistema za napovedovanje povpraševanja.

Natančnost napovedi spremljamo na mesečni osnovi za posamezne skupine izdelkov in tako identificiramo skupine, katerim se moramo v prihodnosti pri napovedovanju posebej posvetiti. Izdelki, katerih povpraševanje napovedujemo, se prodajajo na različnih trgih, vendar nas pri izračunu natančnosti napovedi zanima povpraševanje po izdelku kot celota. Izračunana napoved je namreč vhod v planiranje proizvodnje in tako ni bistvenega pomena, na katerem trgu se bo izdelek prodajal. Tako moramo pred izračunom natančnosti napovedi združiti podatke iz posameznih trgov. Natančnost napovedi se najprej izračuna za vsak izdelek posebej. Nato izračunamo oteženo povprečje, kjer za utež vzamemo delež prodane količine izdelka v celotni prodani količini. Enačbe za izračun natančnosti napovedi za določen mesec so sledeče:

$$Acc = \sum_{\forall X} (Acc(x) * W(x)), \quad (4.59)$$

$$Acc(x) = 1 - \frac{|R_q(x) - F_q(x)|}{R_q(x)}, \quad (4.60)$$



Slika 4.3: Prikaz povečanja natančnosti napovedi povpraševanja z implementacijo sistema za napovedovanje.

$$W(x) = \frac{R_q(x)}{\sum_{\forall i} R_q(i)}, \quad (4.61)$$

kjer Acc predstavlja natančnost napovedi, $Acc(x)$ natančnost napovedi posameznega izdelka, $w(x)$ utež posameznega izdelka, $R_q(x)$ prodano količino izdelka x in $F(x)$ napovedano prodajno količino izdelka x .

Poglavje 5

Zaključek

V diplomskem delu je podrobno opisan algoritem napovedovanja povpraševanja, ki smo ga izdelali v okviru lastne rešitve za napovedovanje povpraševanja kot odgovor na zahteve vodstva po stalnih izboljšavah. Pri izdelavi lastne rešitve smo prišli do velikih izboljšav v procesu napovedovanja ter izboljšali natančnost napovedi. Kljub temu naj bi bila uporaba lastne rešitve le kratkoročna, saj naj bi zaradi velikosti skupine Danfoss, katere del je tudi podjetje Danfoss Trata, d. o. o., ter njene politike uporabe SAP-a kot strateškega orodja, dolgoročno vseeno prešli na uporabo SAP APO sistema. Zaenkrat je lastna rešitev preseгла pričakovanja in se tako še ne razmišlja o njeni zamenjavi. Poleg večje natančnosti napovedi, povečali smo jo za 9-odstotnih točk, ima izdelana rešitev še druge prednosti. Zmanjšali smo število zaposlenih, ki so potrebni za izdelavo napovedi, ter z avtomatizacijo prešli iz ročne izdelave celotne napovedi na obravnavanje izjemnih primerov. Poleg tega imajo planerji sedaj več časa za komunikacijo s prodajnimi trgi, jasnejšo sliko o stanju na trgih in porabijo manj časa za vnos sprememb v napoved.

Izdelana rešitev je prinesla veliko izboljšav, poleg tega so se z njeno uporabo sčasoma pokazale tudi nove možnosti. Sedaj imamo rešitev, v katero lahko enostavno dodamo nove funkcionalnosti in razširitve:

1. Ena izmed možnosti je na primer dodajanje še dodatnih modelov napovedovanja, med katerimi lahko algoritem izbira ter na ta način dodatno izboljšamo natančnost.
2. V algoritmu smo omogočili, da lahko uporabniki popravljajo napoved za celotno družino izdelkov z določenimi posrednimi faktorji, vendar pa se je pokazala potreba, da bi to naredili neposredno z določanjem procentualnega povečanja.

3. Z leti uporabe smo prišli do precej obsežne baze podatkov, ki pa je algoritem trenutno ne uporablja popolnoma, saj je omejen na zadnji dve leti prodaje. Naslednji korak je vključitev vse razpoložljive zgodovine.
4. V času nastajanja orodja so v oddelku prodaje razvili svoj proces planiranja prodajnih pričakovanj, kar bi bilo smiselno povezati v en sistem.

To so le nekatere izmed izboljšav, ki bi še povečale uporabnost rešitve za napovedovanje povpraševanja.

Dodatek A

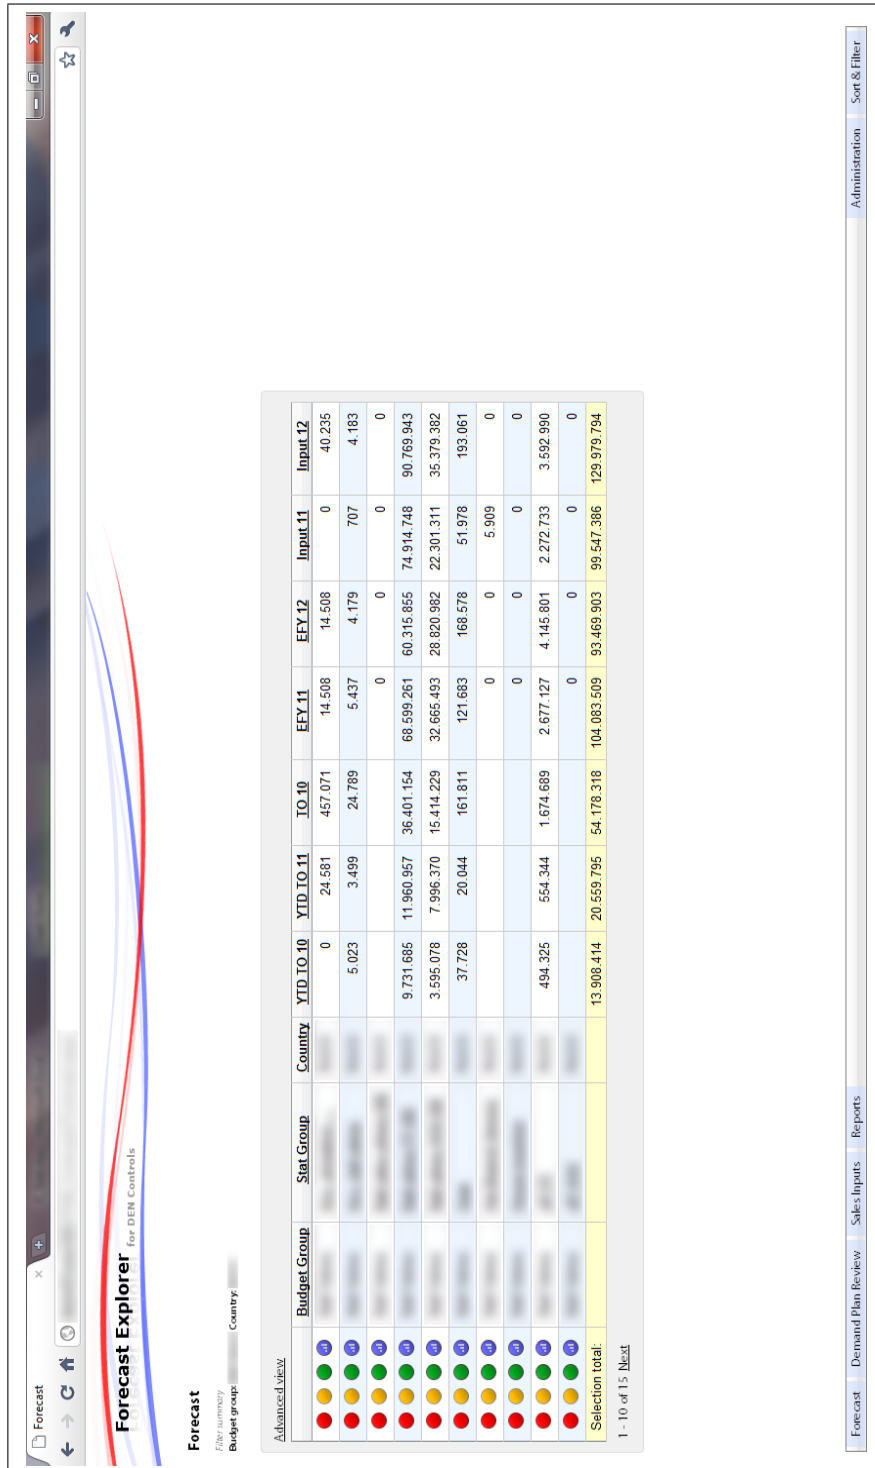
Forecast Explorer

A.1 Opis

Forecast Explorer je sistem napovedovanje povpraševanja, ki smo ga razvili v podjetju Danfoss Trata, d. o. o. Jedro sistema predstavlja algoritem napovedovanja povpraševanja, ki skrbi za avtomatski izračun napovedi. Sistem je uporabnikom dostopen preko spletnega brskalnika. Poleg avtomatskega izračuna napovedi omogoča še druge funkcionalnosti, med katerimi so pomembnejše:

- možnost prilagajanja delovanja algoritma napovedovanja,
- pregledovanje konsolidirane napovedi,
- pregledovanje in spreminjanje detajlne napovedi,
- grafična predstavitev napovedi,
- izdelava poročil,
- administracija matičnih podatkov,
- izvoz podatkov napovedi v druge sisteme (SAP, Excel ...).

Slike A.1, A.2, A.3 in A.4 prikazujejo pomembnejše uporabniške vmesnike.



Slika A.1: Pregled konsolidirane napovedi.

Forecast Explorer
for DEN Controls

Demand Plan Review
Filter Summary: Budget group: Country: 1 - 20 of 158 Next

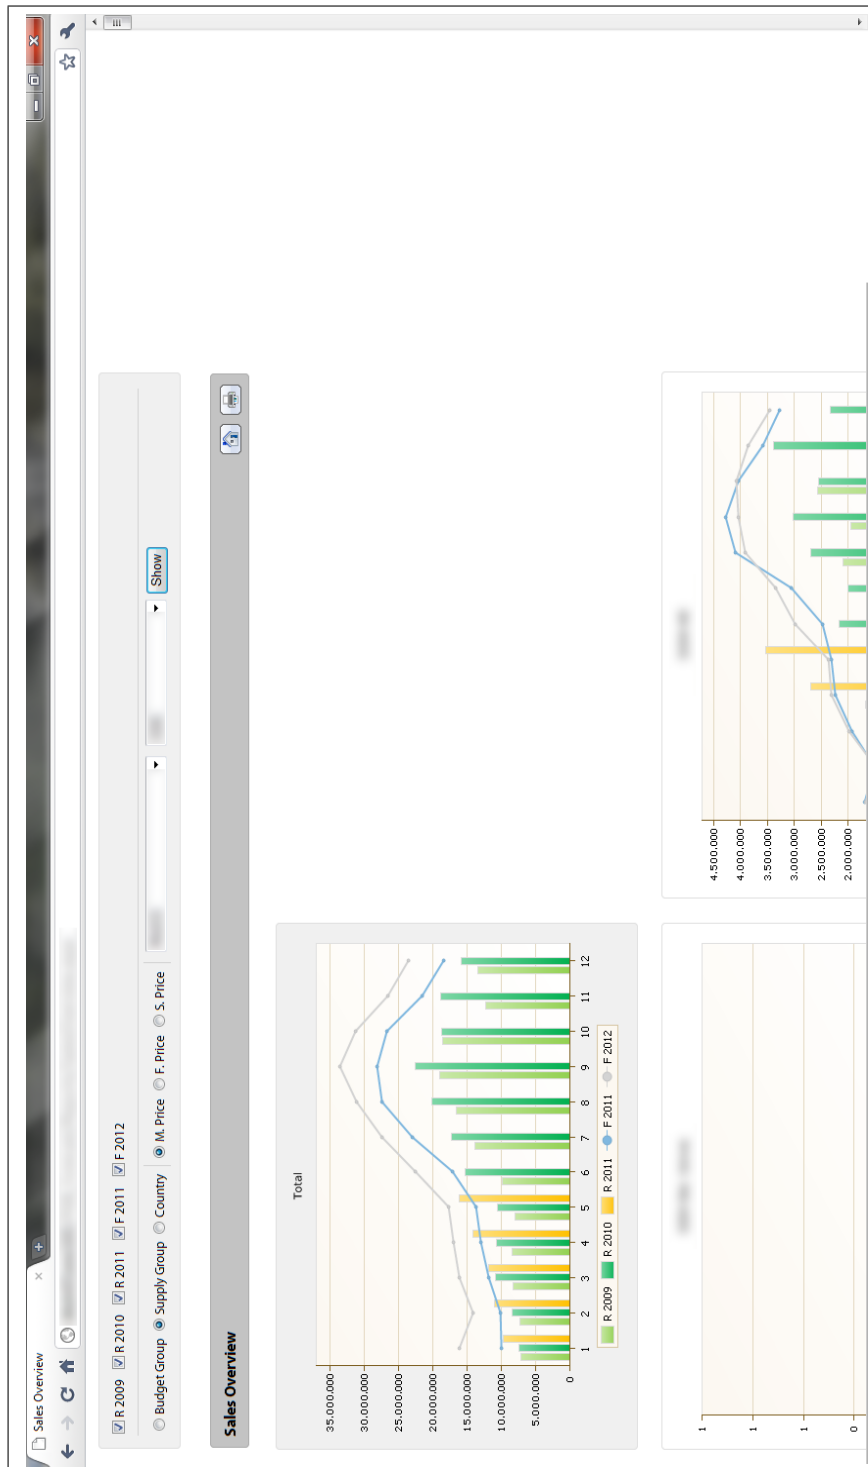
Country	Item	R 09	R 10	EFY 11	EFY 12	Comment						
(NIC)		4045	5022	8023	8650							
R 10	78	337	367	893	360	642	339	574	582	337	236	267
R 11	71	211	303	158	535	0	0	0	0	0	0	0
F 11	322	288*	288*	432*	778*	1211*	1038*	1383*	1211*	778*	346*	0
F 12	288	289	288	433	432	793	1225	1082	1441	1226	793	360

Country	Item	R 09	R 10	EFY 11	EFY 12	Comment						
(NIC)		1992	2628	5039	5000							
R 10	78	132	148	199	313	221	171	127	306	547	227	
R 11	7	204	353	67	294	0	0	0	0	0	0	
F 11	221	158*	158*	264*	475*	738*	633*	844*	738*	475*	211*	0
F 12	167	166	167	250	250	458	709	625	833	708	459	208

Country	Item	R 09	R 10	EFY 11	EFY 12	Comment						
(NIC)		4556	4461	8289	9500							
R 10	134	174	247	338	34	594	808	489	27	1075	65	476
R 11	564	323	432	168	573	0	0	0	0	0	0	0
F 11	381	350*	350*	389*	719*	1118*	958*	1278*	1118*	719*	319*	0

Sort & Filter: Show 2009, Show 2010, Filter, Budget Group, Stat Group, Items, Item Type, Country, R 09, R 10, EFY 11, EFY 12, Manual Yearly 11, Manual Yearly 12, Log ABC, PL, Product Status, Supply Group, Loc ABC, Source Channel, All Source Channels, Standard Comment, Comment, Sort, Don't sort, Show

Slika A.2: Pregled in spreminjanje detaljne napovedi.



Slika A.3: Izdelava poročila.

Forecast Explorer
for DEN Controls

Item Details

Type Item All Countries

Item	Country	Supply Group	Loc. ABC	Source Plant	Source Channel	M. Price	MIIC
		SIDH HD		8200	CDC	4597.60	<input type="checkbox"/>
		SIDH HD		8200	CDC	4956.00	<input type="checkbox"/>
		SIDH HD		8200	CDC	6115.00	<input type="checkbox"/>
		SIDH HD		8200	CDC	4101.50	<input type="checkbox"/>
		SIDH HD		8200	CDC	3953.00	<input type="checkbox"/>
		SIDH HD		8200	CDC	5441.00	<input type="checkbox"/>
		CNDHA HD		8860	China DC	2722.00	<input type="checkbox"/>
		SIDH HD		8200	CDC	2882.00	<input type="checkbox"/>
		SIDH HD		8200	CDC	6923.00	<input type="checkbox"/>
		SIDH HD		8200	CDC	2853.46	<input type="checkbox"/>

Save 1 - 10 of 20902 Next

[Home](#)
[Administration](#)
[Budget Groups](#)
[Stat Groups](#)
[Countries](#)
[Calendars](#)
[Items](#)
[BOM Items](#)
[Item Details](#)
[Supply Groups](#)
[Source Plants](#)
[Source Channels](#)
[Standard Comments](#)
[Global Variables](#)
[Offline Table Editor](#)
[Run DP Calculation](#)
[Generate](#)
[Login](#)

Slika A.4: Administracija matičnih podatkov.

A.2 Uporabljene tehnologije

Sistem napovedovanja povpraševanja je bil razvit na Microsoftovi platformi ASP.NET z uporabo razvojnega okolja Visual Studio 2008. Programska koda je napisana v jeziku C#. Za gostovanje sistema smo uporabili spletni strežnik Microsoft IIS 7.0, za shranjevanje podatkov pa podatkovni strežnik Microsoft SQL Server 2008. Pri razvoju smo uporabili nekatere dodatne knjižnice, med katerimi izstopata odprtokodna knjižnica jQuery ter knjižnica XtraCharts podjetja DevExpress.

Slike

2.1	Prikaz deležev uporabe različnih modelov napovedovanja [1].	9
2.2	Prikaz dekompozicije časovne vrste na osnovne komponente [10].	11
2.3	Prikaz različnih vzorcev glede na Pegelsovo klasifikacijo [3].	13
3.1	Prikaz organizacije skupine Danfoss [8].	16
3.2	Prikaz procesa napovedovanja v podjetju Danfoss Trata, d. o. o.	17
3.3	Prikaz glajenja projektov na določenem izdelku.	20
3.4	Prikaz ročnega popravka na nivoju izdelka.	21
3.5	Prikaz povprečne količine prodaje izdelkov tipa A za dve različni družini izdelkov.	22
3.6	Prikaz povprečne količine prodaje izdelkov tipa B za dve različni družini izdelkov.	24
3.7	Prikaz povprečne količine prodaje izdelkov tipa C za dve različni družini izdelkov.	25
3.8	Prikaz celotno količino prodaje izdelkov tipa A za dve različni družini izdelkov.	26
4.1	Prikaz algoritma napovedovanja povpraševanja.	29
4.2	Prikaz podatkovnega polja.	37
4.3	Prikaz povečanja natančnosti napovedi povpraševanja z implementacijo sistema za napovedovanje.	53
A.1	Pregled konsolidirane napovedi.	58
A.2	Pregled in spreminjanje detajlne napovedi.	59
A.3	Izdelava poročila.	60
A.4	Administracija matičnih podatkov.	61

Tabele

4.1	Prikaz tabel Item in Item Details.	31
4.2	Prikaz tabele Forecast.	32
4.3	Prikaz tabele Demand Plan Realisation.	33
4.4	Prikaz tabele Alternate Seasonality.	34
4.5	Prikaz tabele Budget Group Corrections.	35
4.6	Prikaz tabele Demand Plan.	37

Literatura

- [1] C. L. Jain, "Benchmarking forecasting models" *The journal of business forecasting*, zima 2007-2008.
- [2] M. Leonard, B. Elsheimer, M. John, U. Sglavo, *Small Improvements Causing Substantial Savings - Forecasting Intermittent Demand Data Using SAS® Forecast Server*, SAS Institute Inc., 2008.
- [3] H. Levenbach, J. P. Cleary, *Forecasting: Practice and Process for Demand Management*, Duxbury Press, 2005, p. 3-8.
- [4] T. Ljubič, *Planiranje in vodenje proizvodnje*, Fakulteta za organizacijske vede, 2001.
- [5] S. G. Makridakis, S. C. Wheelwright, R. J. Hyndman, *Forecasting: Methods and Applications*, Wiley, 1997, p. 2-4.
- [6] N. R. Sanders, "When and how should Statistical forecasts be judgmentally adjusted," *Foresight*, št. 6, 2005.
- [7] M. Tanko, *"In-house" vs. "Off the shelf" Demand planning software implementation*, Danfoss, 2009.
- [8] (2011) Danfoss. Dostopno na:
<http://www.danfoss.com>
- [9] (2011) Danfoss Trata. Dostopno na:
<http://www.trata.danfoss.com>
- [10] (2011) An R Time Series Tutorial. Dostopno na:
http://www.stat.pitt.edu/stoffer/tsa2/R_time_series_quick_fix.htm