

█ Odkrivanje znanja iz podatkov z orodjem Orange za napredno nastavitve oskrbovalnih politik

Eva Krhač, Benjamin Urh, Matjaž Roblek

Univerza v Mariboru, Fakulteta za organizacijske vede, Kidričeva cesta 55a, 4000 Kranj
eva.krhac1@um.si; benjamin.urh@fov.uni-mb.si; matjaz.roblek@um.si

Izvleček

V prispevku analiziramo potrebe podjetij po zalogah ter predstavljamo optimalen način obvladovanja zalog na primeru izbranega podjetja. Cilj raziskave je bil najti naprednejši način za obdelavo podatkov o izdelkih in določevanje politik obvladovanja zalog. Pri tem smo upoštevali te kriterije: analiza A-B-C, analiza x-y-z, sezonsko gibanje, velikost artikla, življenjski cikel artikla, poreklo dobavitelja, dobavni čas artikla in distribucija (dostava) artikla. Pri analizi kriterijev, ki vplivajo na določitev optimalne politike oskrbe in vodenje zalog, smo uporabili orodje Orange. Ugotovili smo, da je model uporaben v praksi.

Ključne besede: menedžment zalog, oskrbovalne politike, odkrivanje znanja iz podatkov, orodje Orange.

Abstract

Knowledge discovery from data with the Orange toolkit for the advanced setting of supply policies

In this paper, we analyze the needs of companies for inventories and present the optimal method of inventory management on the example of the selected company. The aim of the research was to establish a more advanced method of processing products data and determination of inventory management policies. The following criteria were taken into consideration: ABC analysis, XYZ analysis, seasonal changes, product size, product life cycle, the origin of the supplier, product delivery time and continued delivery of the product. In the analysis of criteria that affect the determination of the optimal supply policy and inventory management, we employed the Orange toolkit. We have found the model useful in practice.

Keywords: inventory management, supply policies, knowledge discovery from data, Orange toolkit.

1 UVOD

Obvladovanje zalog v trgovinskih podjetjih se ciljno posveča izogibanju previsoki in prenizki zalogi. Iščemo tiste ravni zalog, s katerimi je omogočeno doseganje visoke stopnje servisiranja kupcev, istočasno pa se obseg denarnih sredstev, vezanih v zaloge, bistveno ne poveča (Grčar, 2010). Z vidika skladišnega poslovanja zalogo razumemo kot neko količino določenega blaga, odloženega ali uskladiščenega na določenem kraju – v skladišču v podjetju (Ljubič, 2000). Pri tem naj bi bila optimalna zaloga tista, pri kateri bodo ob maksimalni zanesljivosti poslovanja stroški zalog minimalni (Završnik, 2008). Višina optimalne zaloge se konstantno spreminja in je odvisna od spreminjanja različnih dejavnikov, ki vplivajo na zalogo (Grčar, 2010). Torej neki statično in enkratno določeni model vodenja zalog ni optimalen, ko gre izdelek skozi različne faze svojega življenjskega cikla.

Z vidika stopnje servisiranja stranke so pomembni individualni parametri posameznega izdelka, s katerimi zagotavljamo zeleno stopnjo. Z vidika celovitega upravljanja zalog podjetja pa je pomembno, da zaloge izdelkov s podobnimi lastnostmi določamo z enako nabavno politiko, da bi poenotili postopke naročanja in samo avtomatizacijo naročanja (povečali učinkovitost upravljanja zalog). Cilj je, da porabljamo čim manj virov za določanje čim bolj optimalnih zalog. V tem primeru potrebujemo kriterije, po katerih bomo izdelke opredelili in razvrstili v skupine ter jim določili najprimernejše politike obvladovanja zalog. Pomembno je tudi, da bomo lahko pravočasno zaznali spremembe tržnih ali oskrbovalnih parametrov ter spremenili politike oskrbe posameznim izdelkom tako, da jih bomo razvrstili v bolj optimalne skupine.

V dostopni literaturi smo zasledili različne modele razvrščanja izdelkov, na podlagi katerih izdelkom dodelujemo oskrbovalne politike ter posledično določamo količino zalog in zagotavljamo optimalne ravni zalog v skladu z najboljšo prakso:

- klasifikacijski model A-B-C (opisan v Stevenson, 2015; Heizer in Render, 2004), ki razvršča izdelke po kriteriju vrednosti (produkt cene in količine) v tiste z višjo vrednostjo (razred A) in v tiste z nizko vrednostjo (razred C),
- nadgrajeni klasifikacijski model A-B-C z vključeno analizo x-y-z (Scholz-Reiter, Heger, Meinecke in Bergmann, 2012), ki dodatno razvršča izdelke po kriteriju dinamike porabe, in
- večkriterijske klasifikacijske modele (Bucher in Meissner, 2010), pri katerih poleg kriterijev A-B-C in x-y-z, dodatno razvrščamo po skupinah kriterijev strategije MRP, procedure MRP, varnostne zaloge in velikosti naročilne količine.

Cilj raziskave je bil najti naprednejši način za obdelavo podatkov večkriterijskih klasifikacijskih modelov za določevanje politik obvladovanja zalog.

V ta namen smo testirali primernost orodja Orange, ki je odprtokodno orodje za vizualizacijo in analizo podatkov, razvito v Laboratoriju za bioinformatiko na Fakulteti za računalništvo in informatiko Univerze v Ljubljani. Orodje Orange podpira KDD (angl. Knowledge Discovery from Data, odkrivanje znanja iz podatkov). KDD je netrivialen proces odkrivanja implicitnega, doslej neznanega in potencialno uporabnega znanja iz podatkov (Kljajić, 2015). Glavna ideja je razvoj sistema ali orodja, s katerim bomo pregledali ogromno število podatkov, odkrili vzorce in zakonitosti v njih ter se na podlagi tega naučili napovedati prihodnje vrednosti.

Rударjenje podatkov je sistematičen način pridobivanja koristnih informacij iz bogatih zbirk podatkov s pomočjo kompleksnih algoritmov in tehnik. Vsak proces podatkovnega rudarjenja je sestavljen iz šestih pomembnih korakov: definiranje problema, pridobitev znanja, izbor podatkov, korekcija pomanjkljivih in podvojenih podatkov, analiza in interpretacija ter poročanje in uporaba (Senthilkumaran idr., 2016).

Tehnike podatkovnega rudarjenja vse pogosteje uporabljamo na različnih področjih:

- v farmacevtski industriji in njenih izboljšavah lahko uporabijo te tehnike: iskanje ponavljajočih vzorcev z uporabo pravil rudarjenja podatkov,

klasifikacija zdravil in napovedi o prihodnosti ter tehnike združevanja zdravil (Senthilkumaran idr., 2016),

- pri izboljšanju strategije telemarketinga v bančnih institucijah (za določanje predvidljivosti demografskih in finančnih lastnosti strank ter določanje najbolj vplivnih dejavnikov) – v raziskavi je bilo uporabljeno orodje Orange (Ejaz, 2016).

Pri pregledovanju dostopnih virov smo ugotovili, da se povečuje tudi število objav s področja uporabe tehnik podatkovnega rudarjenja pri menedžmentu zalog: podpora upravljanju dobavne verige krvnih zalog (Delen, 2011), napovedovanje povpraševanja v trgovinskih verigah (Bala, 2012), predvidevanje potreb po medicinskih pripomočkih (Lee in Palaniappan, 2014) in predvidevanje stanja zalog rezervnih delov v avtomobilski industriji (Stefanovic, 2015).

Kot realni primer smo uporabili izbrano podjetje, katerega primarna dejavnost je prodaja gume-notehničnih izdelkov (maloprodaja, veleprodaja) na območju Slovenije, Evropske unije ter na območju nekdanje Jugoslavije (Kovač, 2015). Glavna težava, s katero se sooča podjetje, je obvladovanje zalog – gre tako za prekomerne zaloge določenih izdelkov kot tudi za pomanjkanje zalog drugih izdelkov. Prekomerne zaloge jim povzročajo nepotrebne stroške zalog in skladiščenja, pomanjkanje zalog pa stroške nezaloženosti (oziroma pomanjkanja) in posledično tudi izgubo strank. Trenutna praksa v podjetju je naročanje zalog na podlagi kvalitativne metode, ki temelji predvsem na subjektivni presoji direktorja podjetja, komercialistov ter poslovodje. Ko se zaloga artikla zelo zmanjša, naročijo novo zalogo – pri tem upoštevajo dobavni čas ter ceno artikla. S pomočjo orodja Orange smo želeli pridobiti nabor politik obvladovanja zalog, primernih za izbrano podjetje.

V prispevku predstavljamo uporabo orodja Orange, ki na podlagi dane množice učnih podatkov (ki vsebujejo sklop izbranih kriterijev) odkrije vzorce in zakonitosti v njih ter konstruira pravila za napovedovanje prihodnjih vrednosti. V drugem razdelku predstavljamo izbrane kriterije za določevanje politik za obvladovanje zalog. V naslednjem razdelku predstavljamo razvrščanje artiklov po izbranih kriterijih; odločitvene razrede ter podatkovni model, oblikovan za vnos podatkov v orodje Orange. V četrtem razdelku so predstavljeni numerični rezultati poteka opravljene raziskave (npr. rezultati razvrščanja artiklov glede na kriterije in odločitvene razrede; analiza

stopnje povezanosti odločitvenih razredov s posameznimi kriteriji na podlagi linearne projekcije; analiza s pomočjo nomograma; algoritem CN2, konstrukcija pravil za bodoči način naročanja; analiza natančnosti napovedi različnih uporabljenih klasifikatorjev; analiza matrike napake Bayesovega klasifikacijskega modela; validacija napovedovanja (predikcije) klasifikatorjev Bayes, kNN in klasifikacijsko drevo). V zadnja dva razdelka smo dodali kratko razpravo o dobljenih rezultatih, sklepne ugotovitve ter predloge za praktično uporabo ugotovitev v izbranem podjetju.

2 METODA DELA

V prvem delu je bila opravljena teoretična raziskava strokovne literature ter gradiva s področja menedžmenta zalog, v kateri smo raziskali njihov pomen, vrste ter možne stroške, ki nastajajo kot njihova posledica. Prav tako smo raziskali politike ravnanja z zalogami in kazalce upravljanja z zalogami. V drugem, empiričnem delu smo predlagali primerne politike ravnanja z zalogami za posamezne skupine artiklov. Najprej smo naredili analizo trenutnega stanja vodenja zalog v izbranem podjetju: prikazali poslovni model, razložili obstoječe politike ravnanja z zalogami in prikazali trenutno stanje zalog. Potrebne podatke smo pridobili od podjetja, in sicer del podatkov iz pogovorov z zaposlenimi v podjetju, drugi del podatkov o artiklih pa so zaposleni izvozili iz programa VASCO v Microsoft Excel. Artikle smo razvrstili v skupine s pomočjo osmih kriterijev, ki smo jih izbrali glede na značilnosti izbranega podjetja (trgovsko podjetje) – iz večkriterijske klasifikacije po Bucher in Meissner (2010) smo izločili vse kriterije, ki se nanašajo na distribucijska in proizvodna podjetja. Ostalo je pet kriterijev.

- **Analiza A-B-C (kriterij K1)** je pomemben kriterij, ker trgovsko blago razvrsti po vrednosti od tistega z najvišjo vrednostjo proti tistemu z najnižjo vrednostjo v tri razrede (A, B, C). Vendar analiza A-B-C ne upošteva dinamike porabe in posledično ne zadostuje za smotrno odločanje pri planiranju materialnih potreb.
- **Analiza x-y-z (kriterij K2)** je pomemben kriterij z vidika analize stabilnosti in ustaljenosti porabe ter zanesljivosti napovedovanja porabe (upošteva tudi dinamiko porabe); blago razvrsti po skupinah od tistih, pri katerih poteka poraba daljše časovno obdobje, onih, pri katerih je stalna in pribli-

žno enaka v vseh terminskih enotah (x), do tistih, pri katerih je poraba občasna in je njena napoved posledično nezanesljiva (z).

- **Sezonsko gibanje (kriterij K3)**, je pomemben kriterij z vidika določanja cikla sezonskega nihanja porabe blaga.
- **Velikost artikla (kriterij K4)** je pomemben kriterij z vidika stroškov transporta in skladiščenja blaga.
- **Življenjski cikel artikla (kriterij K5)** je pomemben kriterij z vidika oblikovanja strategije nakupa in trženja blaga glede na fazo v življenjskem ciklu prodajnega artikla.

Poleg navedenih kriterijev za razvrščanje artiklov smo v analizo vključili še kriterije, pomembne za izbrano podjetje (ki so se v podjetju izoblikovali na podlagi izkušenj iz preteklih let):

- **poreklo dobavitelja (kriterij K6)**,
- **dobavni čas artikla (kriterij K7)**,
- **distribucija (dostava) artikla (kriterij K8)**.

V nadaljevanju smo uporabili orodje Orange, ki nam je pomagalo pri osnovni statistiki ter ugotovitvi vrstnega reda pomembnosti kriterijev. Politike obvladovanja zalog smo predlagali na podlagi teoretične raziskave, primerjave z že obstoječimi primeri, raziskanimi kvantitativnimi metodami napovedovanja ter na podlagi izkušenj in predlogov zaposlenih v podjetju.

3 RAZISKAVA

3.1 Določitev skupin za kriterije

V podjetju smo pridobili podatke za 3.694 artiklov, ki se nahajajo v njihovem prodajnem programu. Za zgoraj navedene kriterije smo najprej definirali intervale vrednosti za posamezno skupino znotraj kriterijev od K1 do K5. V naslednjem koraku smo artikle razvrstili po skupinah navedenih kriterijev. Pri izdelavi analize A-B-C (K1) smo uporabili podatke o porabljeni količini v letu 2015 in letni vrednosti. Za izdelavo analize x-y-z (K2) pa podatke o porabi po terminskih enotah (mesecih) v letu 2015. Enake podatke, vendar za zadnja tri leta, smo uporabili tudi za razvrščanje artiklov po kriteriju sezonsko gibanje (K3), s pomočjo katerega smo želeli preveriti sezonska nihanja. Pri sezonskem kriteriju (K3) smo uporabili naslednja pravila (Ljubič, 2008): cikel nihanja od enega maksimuma/minimuma do drugega maksimuma/minimuma je eno leto, maksimum in minimum sta vedno v istem obdobju ciklusa, odstopanje maksimuma/minimuma

od povprečja je večje od polovice standardnega odklona. Pri kriteriju velikost artikla (K4) smo artikle razdelili po principu analize LMN, ki temelji na volumnu. L predstavlja materialne postavke velikega volumna, M materialne postavke srednjega volumna in N materialne postavke malega volumna. Analiza se uporablja predvsem pri določanju dimenzij skladišča ali transportnih sredstev (Brajnović, 2014). Analizo LMN smo prilagodili potrebam podjetja ter artikle razdelili iz treh v pet skupin:

- skupina 1 – artikli, ki spadajo v skupino 0 cm * 0 cm do 25 cm * 25 cm,
- skupina 2 – artikli, ki spadajo v skupino 26 cm * 26 cm do 50 cm * 50 cm,
- skupina 3 – artikli, ki spadajo v skupino 51 cm * 51 cm do 75 cm * 75 cm,
- skupina 4 – artikli, ki spadajo v skupino 76 cm * 76 cm do 100 cm * 100 cm,
- skupina 5 – artikli, ki spadajo v skupino nad 101 cm * 101 cm.

Kriterij življenjski cikel artikla (K5) je sestavljen iz petih faz (Product life cycle, 2009). Vsaka faza za prodajalca pomeni drugačen izziv in različen nivo donosov, vsaka zahteva drugačno strategijo trženja, financiranja, proizvodnje, nakupa in kadrovanja (Urh, 2012). Kriterij življenjski cikel artikla smo delno prilagodili in artikle razdelili na tri skupine, in sicer U (uvajanje), Z (zrelost) in P (upadanje). V katero skupino spada posamezni artikel, smo se odločali na podlagi razlik v prodaji. Pri tem smo preučevali prodane količine (seštevek prodane količine) in porabo po mesecih v zadnjih treh letih. Primerjali smo tudi, koliko mesecev v letih se je artikel prodajal ter znane želje kupcev, dobaviteljev in samega podjetja.

Za kriterije K6 do K8 smo prevzeli delitev artiklov po skupinah, ki jo uporabljajo v podjetju. Pri kriteriju poreklo dobavitelja (K6) smo dobili 11 skupin, in si-

cer Češka republika, Indija, Indonezija, Italija, Kitajska, Madžarska, Nemčija, Poljska, Slovenija, Srbija in Turčija. Kriterij dobavni čas artikla (K7) opredeljuje, v koliko tednih od trenutka naročila je artikel dostavljen v podjetje. Kriterij je vezan na prejšnji kriterij, saj je dobavni čas artikla odvisen od tega, iz katere države prihaja artikel. Pri tem kriteriju smo tako dobili osem skupin, in sicer:

- en teden – artikli iz Slovenije, Italije in Nemčije,
- dva tedna – artikli iz Turčije, Srbije, Italije, Madžarske in Češke republike,
- tri tedne – artikli iz Italije in Nemčije,
- štiri tedne – artikli iz Italije, Nemčije in Češke republike,
- šest tednov – artikli iz Poljske,
- 12 tednov – artikli iz Turčije, Kitajske in Indije,
- 18 tednov – artikli iz Indonezije,
- 26 tednov – artikli iz Nemčije.

V zadnjem kriteriju – distribucija (dostava) artiklov (K8) – smo določili, ali se artikel prodaja v Sloveniji ali tujini ali v Sloveniji in tudi v tujini.

3.2 Obdelava podatkov v orodju Orange in tabela povezanosti izbranih kriterijev (K1, K2, K5, K7) glede na odločitvene razrede

Najprej smo izdelali podatkovni model v orodju Orange, sestavljen iz diskretnih podatkov – atributov (ki so jih predstavljali izbrani kriteriji) in iz treh odločitvenih razredov (O1, O2, O3):

- izdelki se naročajo na podlagi statističnih izračunov (O1),
- izdelki se naročajo na podlagi preteklih izkušenj komercialistov (O2),
- izdelki se ne naročajo na zalogo (O3).

Tabela 1 prikazuje pravila, na podlagi katerih smo se odločali pri določanju odločitvenih razredov (O_i, i = 1, 2, 3).

Tabela 1: Lastnosti atributov (izbranih kriterijev K1, K2, K5, K7) za odločitvene razrede (O_i, i = 1, 2, 3)

Atributi – 4 izbrani kriteriji/odločitveni razredi	A-B-C (K1)	x-y-z (K2)	Življenjski cikel (K5)	Dobavni čas (K7)
Izdelki se naročajo na podlagi statističnih izračunov (O1)	Za artikle A; za artikle B; za artikle C	x, y in z; x, y in z; x in y	Vse tri faze	Vsi dobavni časi
Izdelki se naročajo na podlagi preteklih izkušenj komercialistov (O2)	C	z	Z, P	Vsi dobavni časi
Izdelki se ne naročajo na zalogo (O3)	C	z	P	Do 4 tedne

Odločitvene razrede smo določali na podlagi štirih kriterijev (K1, K2, K5, K7), za katere smo na podlagi pregledane literature – K1, K2 (Heizer in Render, 2004; Scholz-Reiter, Heger, Meinecke in Bergmann, 2012; Stevenson, 2015) – in dosedanjih izkušenj podjetja – K5, K7 – predvidevali, da so bolj pomembni. »Pravila« pri izbranih štirih kriterijih (atributih) so bila oblikovana na podlagi pregledane literature z upoštevanjem izkušenj in želja podjetja pri naročanju artiklov in upravljanju zalog (npr. na zalogo ni treba naročati izdelkov, ki po porabljeni količini in letni vrednosti (analiza A-B-C) spadajo v skupino C; po porabi po terminskih enotah (analiza x-y-z) spadajo v skupino z; so glede na življenjski cikel v upadanju ter imajo rok dobave do 4 tedne). Izbrani podatki so konsistentni, podatkovni model pa ni vseboval manjkajočih ali neznanih vrednosti, saj smo vse take vrednosti nadomestili z najverjetnejšimi, kot nalagajo pravila priprave podatkov za uvoz v orodje Orange. Izdelani podatkovni model smo uvozili v izbrano


orodje Orange ter najprej opravili opisno statistiko razvrstitve artiklov po posameznih kriterijih in odločitvenih razredih.

4 NUMERIČNI REZULTATI


4.1 Rezultati razvrščanja artiklov glede na kriterije K1 do K8 in glede na odločitvene razrede (O1, O2, O3)

Sliki 1 in 2 prikazujeta rezultate razvrščanja artiklov v skupine glede na vsakega izmed osmih kriterijev (K1 do K8) in glede na odločitvene razrede (O1, O2, O3).

Kot vidimo iz slike 1, je analiza A-B-C (kriterij K1 po standardnih mejah za skupine) pokazala, da glede na porabljeno količino in letno vrednost 404 artikli (10,9 %) spadajo v skupino A in so zelo pomembni za poslovanje podjetja. V skupino B pri omenjeni analizi spada 1.171 artiklov (31,7 %), v skupino C pa 2.119 artiklov (57,4 %). Kot vidimo, je največ artiklov C, ki so najmanj pomembni za poslovanje.



Slika 1: Primer prikaza opisne statistike za razvrščanje artiklov glede na posamezne kriterije (K1 do K8) v orodju Orange



Slika 2: Primer prikaza opisne statistike za razvrščanje artiklov glede na odločitvene razrede (01, 02, 03) v orodju Orange

Kar se tiče rezultatov analize x-y-z (kriterij K2), smo ugotovili, da je glede na porabo po terminskih enotah (mesecih) najmanj artiklov skupine x (glej sliko 1), in sicer samo 126 (3,4 %). V to skupino spadajo artikli, za katere lahko zanesljivo napovemo porabo. Naslednji so artikli skupine y, ki jih je 737 (20,0 %), največja pa je skupina artiklov z. Artiklov, ki pripadajo skupini z, je 2.831 (76,6 %). Problem te skupine je, da je njihova napoved porabe nezanesljiva.

Naslednja je bila opravljena opisna statistika za kriterij sezonsko gibanje (kriterij K3), ki je pokazala, da ima samo 292 (7,9 %) artiklov sezonsko nihanje. Pri ostalih 3.402 artiklih (92,1 %) ni bilo zaznano sezonsko nihanje. Naslednji kriterij je bil kriterij K4 – velikost artikla, po katerem je bilo kar 1.646 artiklov (44,6 %) razvrščenih v drugo velikostno skupino, ki je po številu artiklov največja.

Opisna statistika za kriterij K5 je pokazala, da je najmanjša skupina artiklov tista, ki predstavlja artikle v uvajanju v prodajni program podjetja. Skupino sestavlja 831 artiklov, kar je 22,5 % prodajnega programa. Naslednja skupina so artikli v zrelosti, in sicer je takih 1.105 (29,9 %). Največjo skupino sestavljajo artikli, ki so v padanju – takih je 1.758 (47,6 %).

Kar se tiče kriterija K6, smo ugotovili, da najmanj artiklov prihaja iz Madžarske, in sicer samo 5 (0,1 %), največje število artiklov pa prihaja iz Kitajske (24,1 %) in Slovenije (40,8 % prodajnega programa podjetja). Naslednji je bil kriterij dobavni čas (K7), ki je v veliki meri odvisen od kriterija poreklo dobavitelja. Ugotovili smo, da ima 1.692 artiklov (45,8 %) dobavni čas en teden.

Zadnji kriterij, ki smo ga obravnavali, je distribucija (dostava) artiklov (K8), ki nam pove, ali se artikli prodajajo samo v Sloveniji, samo v tujino ali pa povsod. Samo v tujino se prodaja samo 9 artiklov (0,2 %), samo v Sloveniji pa 694 artiklov (18,8 %). Največji delež prodajnega programa podjetja zavzemajo artikli, ki se prodajajo tako v Sloveniji kot tudi v tujini; takih artiklov je 2.991 (81,0 %).


Na koncu smo pogledali koliko artiklov pripada posameznemu odločitvenemu razredu (O_i , $i = 1, 2, 3$) na podlagi »pravil«, ki smo jih sami določili na začetku oblikovanja podatkovnega modela (tabela 1). Izkazalo se je, da je največ artiklov, ki bi jih lahko naročali na podlagi preteklih izkušenj komercialistov. Takih artiklov je 1.861, kar pomeni 50,4 % prodajnega programa podjetja. Naslednji so artikli, ki bi jih v prihodnosti naročali izključno na podlagi statističnih izračunov. Takih artiklov je 1.720, kar pomeni 46,6 % prodajnega programa podjetja. Zadnjo skupino pa sestavljajo artikli, za katere že zdaj lahko rečemo, da jih v prihodnosti ne bo treba naročati na zalogo. Takih artiklov je 113, kar je 3,1 % prodajnega programa podjetja.

V naslednjem koraku nas je zanimalo, kateri kriteriji so bolj pomembni za razvrstitev artiklov. Predpostavili smo, da lahko sestavimo dve skupini glede pomembnosti kriterijev, in sicer:

- zelo pomembni kriteriji: analiza A-B-C, analiza x-y-z, življenjski cikel artikla, dobavni čas artikla,
- manj pomembni kriteriji: poreklo dobavitelja, distribucija (dostava) artikla, sezonsko gibanje, velikost artikla.

4.2 Analiza stopnje povezanosti odločitvenih razredov s posameznimi kriteriji na podlagi linearne projekcije

Da bi ugotovili pomembnost kriterijev za razvrstitev artiklov, smo uporabili vizualizacijo linearne projekcije (angl. *Linear Projection*). Vizualizacija linearne projekcije prikazuje projekcije podatkov, označenih z odločitvenimi razredi. Pri tem podpira različne vrste projekcij: krožno, linearno diskriminacijsko analizo, analizo glavnih komponent, projekcijo po meri (Orange Visual Programming Documentation, Release 3, 2018). Na podlagi razpršenosti točk (slika 3) lahko razberemo, da na naročanje na podlagi preteklih izkušenj komercialistov vplivajo predvsem analiza A-B-C in analiza x-y-z ter v manjši meri tudi sezonsko gibanje



Slika 3: Analiza stopnje povezanosti odločitvenih razredov s posameznimi kriteriji na podlagi linearne projekcije

in distribucija (dostava) artiklov. Na to, da artiklov ne naročajo na zalogo, vplivata predvsem analizi A-B-C in x-y-z; na naročanje na podlagi statističnih izračunov pa vplivajo vsi izbrani kriteriji (atributi).

4.3 Analiza s pomočjo nomograma

V nadaljevanju smo uporabili nomogram (grafični pokazatelj), s pomočjo katerega smo poiskali odgovore na vprašanja o pomembnosti posameznih kriterijev. Nomogram v orodju Orange prikazuje vizualne klasifikacijske modele logistične regresije in Naive Bayesa ter izračunava verjetnosti odločitvenega razreda glede na nabor vrednosti atributov (kriterijev). Omogoča preverjanje, kako spreminjanje vrednosti atributa vpliva na verjetnosti odločitvenega razreda. Skratka, v nomogramu lahko vidimo najvišje uvrščene attribute (kriterije) ter njihov prispevek k verjetnosti ciljnega razreda (Nomogram, 2017). Pri artiklih, ki jih lahko v prihodnosti naročajo na podlagi preteklih izkušenj komercialistov (slika 4), so bolj pomembni kriteriji: analiza A-B-C, analiza x-y-z, dobavni čas artikla in življenjski cikel artikla. Pri artiklih, ki jih lahko v prihodnosti naročajo na podlagi statističnih izračunov, so bolj pomembni kriteriji: analiza A-B-C, analiza x-y-z, življenjski cikel artikla in dobavni čas


artikla. Pri artiklih, ki jih v prihodnje ni treba naročati na zalogo, so bolj pomembni kriteriji: sezonsko gibanje, življenjski cikel artikla, velikost artikla in dobavni čas artikla. Opazili smo, da sta za naročanje na zalogo kriterija distribucija (dostava) artikla in sezonsko gibanje najmanj pomembna:

- pri naročanju na podlagi preteklih izkušenj komercialistov – sedmo in šesto mesto od sedmih kriterijev,
- pri naročanju na podlagi statističnih izračunov – šesto in sedmo mesto od sedmih kriterijev.

Ugotovili smo, da so za naročanje na zalogo bolj pomembni analizi A-B-C in x-y-z, dobavni čas ter življenjski cikel artikla.

4.4 Algoritem CN2, konstrukcija pravil za bodoči način naročanja

V nadaljevanju smo uporabili algoritem CN2 (tabela 2), klasifikacijsko tehniko za učinkovito določanje preprostih, razumljivih pravil v obliki »če – potem« za posamezni predvideni razred (Orange Visual Programming Documentation, Release 3, 2018). Algoritem CN2 nam omogoča, da na podlagi preučeni primerov prikaže pravila, ki jih lahko v nadaljevanju upoštevamo pri razvrščanju artiklov za naročanje na



Slika 4: Primer nomograma za naročanje na podlagi preteklih izkušenj komercialistov

zalogo ali sprotno naročanje. S podatkovnim modelom smo ugotovili, da je 100 % naročil opravljenih na podlagi preteklih izkušenj komercialistov, kadar je artikel C, z in ni sezonski; 100 % naročil opravljenih na podlagi statističnih izračunov, kadar je artikel B ali A, ter da 99 % naročil ne naroča na zalogo, kadar je artikel C, sezonski, v padanju in je njegov dobavni čas en teden.

4.5 Analiza natančnosti napovedi različnih uporabljenih klasifikatorjev

Izmerili smo tudi natančnost klasifikatorjev, ki na podlagi množice že klasificiranih primerov artiklov klasificirajo odločitvene razrede (pravila) za nove

primere artiklov. Uporabili smo štiri klasifikatorje (Naive Bayes, CN2 rules, kNN in Classification Tree) ter tri mere za ocenjevanje učenja (CA, AUC, Brier). CA (angl. Classification accuracy; klasifikacijska točnost) prikaže razmerje med številom pravilno napovedanih in številom vseh napovedanih primerov. V številkah to pomeni, da je cilj pri klasifikacijski točnosti dobiti višjo oceno, ker višja kot je ocena, boljša je kakovost napovedanih primerov. AUC (angl. area under the curve; ploščina pod karakteristično krivuljo delovanja) prikaže verjetnost, da bo klasifikator pravilno razločil med pozitivnimi in negativnimi primeri, torej je cilj dobiti višjo oceno oziroma oceno bližje številki 1,0000. Brierjeva ocena preko vseh

Tabela 2: Pravila, določena z uporabo algoritma CN2

Kakovost pravila	Pokritost	Predvideni razred	Pravilo
1,00	512,00	Izdelki se naročajo na podlagi preteklih izkušenj komercialistov.	ČE artikel > 12419.00 IN analiza A-B-C = C IN analiza x-y-z = z IN Sezonska gibanja = Ni sezona POTEM Način naročanja izdelkov = Izdelki se naročajo na podlagi preteklih izkušenj komercialistov.
1,00	1274,00	Izdelki se naročajo na podlagi preteklih izkušenj komercialistov.	ČE analiza A-B-C = C IN analiza x-y-z = z IN Sezonska gibanja = Ni sezona POTEM Način naročanja izdelkov = Izdelki se naročajo na podlagi preteklih izkušenj komercialistov.
1,00	1171,00	Izdelki se naročajo na podlagi statističnih izračunov.	ČE analiza A-B-C = B POTEM Način naročanja izdelkov = Izdelki se naročajo na podlagi statističnih izračunov.
1,00	404,00	Izdelki se naročajo na podlagi statističnih izračunov.	ČE analiza A-B-C = A POTEM Način naročanja izdelkov = Izdelki se naročajo na podlagi statističnih izračunov.
0,99	83,00	Izdelki se ne naročajo na zalogo.	ČE Sezonska gibanja = Sezona IN Življenjski cikel artikla = P IN Dobavni čas artikla = 1 TEDEN IN analiza A-B-C = C POTEM Način naročanja izdelkov = Izdelki se ne naročajo na zalogo.

testnih primerov oceni različnost med ciljno in dejansko napovedano distribucijo. Idealno je, kadar klasifikator vedno natančno napove pravilni razred, kar nam prikaže številka 0,0000 – torej je cilj, da je Brierjeva ocena čim bližja številki 0,0000. Pri klasifikatorjih CN2 rules in kNN je prišlo do *overfittinga* (v primeru, če sta CA in AUC enaka 1,0000 ter Brierjeva ocena enaka 0,0000), kar pomeni, da sta se klasifikatorja predobro prilagodila podatkom iz učne množice in sta podala slabe rezultate za nove podatke (Kljajić, 2015). Kot vidimo v tabeli 3, ima najboljšo oceno klasifikator Naive Bayes, ki pri danih vrednostih (vseh) atributov izračuna za dani novi primer pogojne verjetnosti za vsak razred.

Tabela 3: Natančnost klasifikatorjev

Metoda	CA	AUC	Brier
Naive Bayes	0,9981	1,0000	0,0104
CN2 rules	1,0000	1,0000	0,0000
kNN	1,0000	1,0000	0,0000
Classification Tree	0,9803	0,9988	0,0241

4.6 Analiza matrice napake Bayesovega klasifikacijskega modela

V nadaljevanju smo uporabili matriko napake (angl. Confusion Matrix), ki vsebuje informacije o dejanskih in klasificiranih napovedih sistema. Matrika je ocena kakovosti klasifikacijskega modela, ki je bil v našem primeru Naive Bayes. Matrika napake je za naročanje artiklov na podlagi preteklih izkušenj komercialistov dosegla 100 % pravilnih odgovorov, za naročanje na podlagi statističnih izračunov 99,6 % pravilnih odgovorov ter za nenaročanje na zalogo prav tako 100 % pravilnih odgovorov (tabela 4).

4.7 Validacija napovedovanja (predikcije) klasifikatorjev Bayes, kNN in klasifikacijsko drevo

Na koncu smo naredili še predikcije, pri katerih na podlagi podatkovnega niza in enega ali več klasifikatorjev orodje Orange izpiše napovedi ter omogoča analizo odločitev napovednih modelov (Orange Visual Programming Documentation, Release 3, 2018). Z njimi smo ugotavljali, kako dobro model napoveduje oziroma kako je model zanesljiv. Pri tem smo uporabili dvanajst naključnih primerov artiklov – po štiri za vsak način naročanja. Na podlagi predikcije smo ugotovili, da so vsi trije klasifikatorji (kNN,

Naive Bayes in Classification Tree) točno napovedali vseh dvanajst naključno izbranih primerov.

5 RAZPRAVA IN PREDLOG SPREMEMB PRI OBVLADOVANJU ZALOG V IZBRANEM PODJETJU

Na podlagi teoretične raziskave smo spoznali značilnosti posameznih politik obvladovanja zalog, kar nam je pomagalo pri ugotovitvi, katera politika je primerna za obvladovanje posameznih zalog. V nadaljevanju je prikazan predlog sprememb pri obvladovanju zalog v izbranem podjetju, ki vključuje uporabo kvalitativnih in kvantitativnih metod za predvidevanje povpraševanja.

Za posamezne skupine artiklov predlagamo uporabo kvantitativnih metod, ki bi morale podati dovolj natančno napoved povpraševanja (tabela 5).

Primer interpretacije tabele: za artikle A-x, zrele ali v padanju, pri vseh dobavnih časih priporočamo model ekonomsko optimalne količine naročila z upoštevanjem količinskih popustov. S priporočenim modelom bi tako podali natančno napoved povpraševanja za 90,36 % vseh artiklov A-x.

Za ostale kombinacije (npr. skupine artiklov A-x, ki so v uvajanju; skupine artiklov A-y, ki so v uvajanju; skupine artiklov A-z idr.) predlagamo uporabo kombinacij kvalitativnih in kvantitativnih metod predvidevanja povpraševanja. Za podjetje je uporabna predvsem napoved prodajnega osebja, ki pri predvidevanju uporablja znanje in izkušnje osebja. Pri tem se je seveda treba zaščititi pred pristranskostjo osebja, zato predlagamo uporabo posameznih orodij in pripomočkov za pridobivanje podatkov in informacij o posameznih pojavih. Za izbrano podjetje so najbolj uporabne in preproste tržne raziskave o artiklih, kot je na primer analogija s preteklostjo istih ali podobnih artiklov. Predlagamo, da pri predvidevanju povpraševanja v podjetju uporabijo obe vrsti metod in rezultate nato primerjajo. V primeru, da bi se v rezultatih pojavila prevelika razlika, so lahko prepričani, da je bilo predvidevanje napačno (oziroma da je izbrana metoda nenatančna).

Na koncu smo pregledali, v kolikšnem odstotku bi lahko izboljšali obvladovanje zalog, ter ugotovili, da predlagane spremembe natančno obvladujejo zaloge pri najmanj 44 % artiklov iz posamezne skupine (v najboljšem primeru pa celo 90,36 % artiklov). Pri tem so ocenjene samo spremembe glede uporabe kvantitativnih metod (tabela 5).

Tabela 4: Matrika napake

	Izdelki se naročajo na podlagi preteklih izkušenj komercialistov.	Izdelki se naročajo na podlagi statističnih izračunov.	Izdelki se ne naročajo na zalogo.	
Izdelki se naročajo na podlagi preteklih izkušenj komercialistov.	100,0 %	0,4 %	0,0 %	1.302
Izdelki se naročajo na podlagi statističnih izračunov.	0,0 %	99,6 %	0,0 %	1.204
Izdelki se ne naročajo na zalogo.	0,0 %	0,0 %	100,0 %	80
	1.297	1.209	80	2.586

Tabela 5: Primerne politike obvladovanja zalog za posamezne lastnosti kriterijev

Deterministično planiranje			
X	Y	Z	
A	Model ekonomsko optimalne količine naročila z upoštevanjem količinskih popustov	Model ekonomsko optimalne količine naročila na podlagi povprečja	
	Zrelost, padanje; vsi dobavni časi (90,36 % artiklov A-x)	Zrelost, padanje; vsi dobavni časi (78,67 % artiklov A-y)	
B	Nabavljanje majhnih količin, ki krijejo potrebe vsake terminske enote		
	Zrelost, padanje; dobavni čas do 1 tedna (27,50 % artiklov B-x-y-z)		
	Nabavljanje velikih količin, ki krijejo potrebe več terminskih enot		
	Zrelost, padanje; dobavni čas vsaj 2 tedna (28,93 % artiklov B-x-y-z)		
C	Stohastično planiranje	Deterministično planiranje	
	Model Q – kontinuirano spremljanje zalog	Model Q – kontinuirano spremljanje zalog	Po dejanskih potrebah
	Zrelost, padanje; krajši dobavni časi (22,22 % artiklov C-x)	Zrelost, padanje; krajši dobavni časi (44,12 % artiklov C-y)	Zrelost, padanje; krajši dobavni časi (61,25 % artiklov C-z)
	Model P – periodično spremljanje zalog		
	Zrelost, padanje; daljši dobavni časi (55,56 % artiklov C-x)		

6 SKLEP

Cilji, ki smo si jih zadali na začetku dela z orodjem Orange, so bili doseženi, kar pomeni, da je model uporaben v praksi. Ne smemo pozabiti še na možnosti izboljšanja podatkovnega modela v prihodnosti, ki pa jih vidimo v bolj relevantnem vzorcu – vsi odločitveni razredi bi morali imeti enako število primerov. Trenutno sta prva dva odločitvena razreda imela veliko večje število primerov kot tretji.

Za uvedbo predlaganih sprememb je treba izpolniti tudi nekaj pogojev. Za dobro obvladovanje zalog je treba najprej dobro poznati lastnosti artiklov, zato je potreben dostop do veliko kakovostnih informacij o artiklih. Za lažje razumevanje vseh informacij je uporabna grafična oblika, ki omogoča tudi krajši čas preučevanja podatkov. Prav tako je pomembno konstantno vodenje statistike napovedi v preteklosti, ki omogoča pregled nad točnostjo napovedi in omogoča hitro prilagajanje na spremembe.

Da bi pri obvladovanju zalog upoštevali vse spre-

membe v zalogah, je treba postopek iz empiričnega dela večkrat ponavljati – predlagamo, da se postopek ponavlja enkrat letno. Pri ponavljanju postopka lahko uvedemo tudi nekaj sprememb. Prva sprememba, ki bi bila smiselna, je sprememba v določanju kriterijev – kriterije, ki so se do zdaj pokazali kot manj pomembni, lahko izločimo iz raziskave, dodamo pa lahko tudi kakšnega novega.

Prav tako bi bilo treba vnaprej pripraviti predloge posameznih analiz in izračunov (v ustreznem programskem orodju), v katere bi vnašali samo spremembe, kar bi omogočilo hitrejše analize in odločanje. Za potrebe raziskave smo zaradi uporabniku prijazne uporabe in dostopnosti do orodja v podjetju večino analiz opravili v Microsoftovemu Excelu. Zaradi začetnega nastavljanja vseh potrebnih tabel smo potrebovali razmeroma veliko časa. Največ težav smo imeli pri pripravljanju podatkov za empirični del z informacijskim sistemom VASCO (ki ga trenutno uporabljajo v podjetju), saj ne omogoča hitrega dosto-

pa do podatkov, potrebnih za opravljanje tovrstnih analiz. Posledično so zaposleni za iskanje podatkov porabili več časa kot je bilo predvideno. Zato kot zadnjo spremembo, ki bi v prihodnje pripomogla k hitrejši in kakovostnejši analizi, predlagamo investicijo v nadgradnjo informacijskega sistema. Nadgradnja bi morala omogočati preprost in hiter dostop do vseh podatkov o preteklosti artiklov. Vendar bi bilo pred tem treba opraviti še finančno analizo upravičenosti investicije v nadgradnjo informacijskega sistema.

7 LITERATURA

- [1] Bala, P. K. (2012). Improving inventory performance with clustering based demand forecasts. *Journal of Modelling in Management* 7(1), 23–37.
- [2] Brajnović, A. (2014). *Upravljanje zalihama u dobavnom lancu*. Diplomsko delo. Rijeka: Pomorski fakultet u Rijeci.
- [3] Bucher, D. in Meissner, J. (2010). *Automatic Parameter Configuration for Inventory Management in SAP ERP/APO*. Management Science Working Paper Series; The Department of Management Science, Lancaster University.
- [4] Delen, D., Erraguntla, M., Mayer, J. R. in Wu, C. N. (2011). Better management of blood supply-chain with GIS-based analytics. *Annals of Operations Research* 185 (1), 181–193.
- [5] Ejaz, S. (2016). *Predicting demographic and financial attributes in a bank marketing dataset* (Master thesis). Arizona: Arizona State University.
- [6] Grčar, G. (2010). *Obvladovanje zalog v podjetju Toko, d. o. o.* Diplomsko delo. Ljubljana: Ekonomska fakulteta.
- [7] Guo, X., Liu, C., Xu, W., Yuan, H. in Wang, M. (2014). *A prediction-based inventory optimization using data mining models*. Prispevek predstavljen na 7. mednarodni konferenci Joint Conference on Computational Sciences and Optimization, CSO, str. 611–615.
- [8] Heizer, J. in Render, B. (2004). *Principles of Operations Management*. Pearson Education, Practice Hall.
- [9] Kljajić Borštnar, M. (2015). *Gradivo za predavanja: Odkrivanje znanja v podatkih*. Kranj: Fakulteta za organizacijske vede.
- [10] Kovač, E. (2012). *Analiza računovodskih izkazov s kazalniki*. Diplomsko delo. Bled: Višja strokovna šola za gostinstvo in turizem Bled.
- [11] Krhač, E. (2016). *Politike obvladovanja zalog v podjetju Gumitehna, d. o. o.* Magistrsko delo. Kranj: Fakulteta za organizacijske vede.
- [12] Lee, C. K. M in Palaniappan, S. (2014). *Effective asset management for hospitals with RFID*. 2014 IEEE International Technology Management Conference, Chicago.
- [13] Ljubič, T. (2000). *Planiranje in vodenje proizvodnje: modeli, metode, podatki*. Kranj: Moderna organizacija.
- [14] Ljubič, T. (2008). *Predvidevanje in napovedovanje v oskrbovalni verigi*. Kranj: Moderna organizacija.
- [15] Nomogram. (2017). *Laboratorij za bioinformatiko, Univerza v Ljubljani*. Pridobljeno 29. 1. 2018 na <https://blog.bioblab.si/2017/06/05/nomogram/>.
- [16] Orange Visual Programming Documentation, Release 3. (2018). *Laboratorij za bioinformatiko, Univerza v Ljubljani*. Pridobljeno 29. 1. 2018 na <https://media.readthedocs.org/pdf/orange-visual-programming/latest/orange-visual-programming.pdf>.
- [17] Product life cycle. (2009). *The Economist*. Pridobljeno 24. 7. 2016 na <http://www.economist.com/node/14301365>.
- [18] Roblek, M. (2013). *Gradivo za predavanja: Predvidevanje, planiranje in operativno vodenje poslovanja*. Kranj: Fakulteta za organizacijske vede.
- [19] Scholz-Reiter, B., Heger, J., Meinecke, C. in Bergmann, J. (2012). Integration of demand forecasts in ABC-xyz analysis: practical investigation at an industrial company. *International Journal of Productivity and Performance Management*, 61(4), 445–451.
- [20] Senthilkumaran, U., Manikandan, N. in Senthilkumar, M. (2016). Role of data mining on pharmaceutical industry – a survey. *International Journal of Pharmacy and Technology* 8(3), 16100–16106.
- [21] Stefanovic, N. (2015). Collaborative predictive business intelligence model for spare parts inventory replenishment. *Computer Science and Information Systems* 12(3), 911–930.
- [22] Stevenson, J. S. (2015). *Operations Management: Inventory Management*. McGrawHill.
- [23] Tsou, C. M. (2013). On the strategy of supply chain collaboration based on dynamic inventory target level management: A theory of constraint perspective. *Applied Mathematical Modelling*, 37, 5204–5214.
- [24] Urh, B. (2012). *Gradivo za predavanja: Razvoj proizvodov in proizvodnih procesov*. Kranj: Fakulteta za organizacijske vede.
- [25] Završnik, B. (2008). *Management nabave in oskrbnih verig*. Maribor: Ekonomsko-poslovna fakulteta.

Eva Krhač je zaposlena na Fakulteti za organizacijske vede Univerze v Mariboru. Habilitirana je v naziv asistentka za področje inženiring poslovnih in delovnih sistemov. Trenutno svoje znanje izpolnjuje na doktorskem študiju iz področja inženiring poslovnih sistemov na Fakulteti za organizacijske vede. Je avtorica ali soavtorica več znanstvenih, strokovnih in drugih publikacij.

Benjamin Urh je višji predavatelj, habilitiran za področje inženiring poslovnih in delovnih sistemov. Na Fakulteti za organizacijske vede Univerze v Mariboru na visokošolskem strokovnem programu predava predmeta Razvoj proizvodov in proizvodnih procesov ter Organizacija proizvodnih procesov. Je avtor ali soavtor več kot sto znanstvenih, strokovnih in drugih publikacij. Raziskovalno delo opravlja na področju prenove poslovnih sistemov in učinkovitosti poslovnih procesov.

Matjaž Roblek je predavatelj na Fakulteti za organizacijske vede Univerze v Mariboru za področja operativnega menedžmenta in menedžmenta oskrbovalnih verig. Je tudi dolgoletni svetovalec za prenovo poslovnih in proizvodnih procesov. Njegovo delo obsega več kot sto zaključenih projektov in svetovanj s področja prenove organizacijskih in informacijskih sistemov.