

UNIVERZA V LJUBLJANI
FAKULTETA ZA DRUŽBENE VEDE

Anja Šostar

Povečevanje zvestobe kupcev z metodami podatkovnega rudarjenja

Magistrsko delo

Ljubljana, 2016

UNIVERZA V LJUBLJANI
FAKULTETA ZA DRUŽBENE VEDE

Anja Šostar

Mentorica: izr. prof. dr. Irena Ograjenšek

Somentorica: red. prof. dr. Nada Lavrač

Povečevanje zvestobe kupcev z metodami podatkovnega rudarjenja

Magistrsko delo

Ljubljana, 2016

ZAHVALA

Zahvaljujem se vsem, ki so mi omogočili izdelati magistrsko delo in me pri mojem delu spodbujali. Posebna zahvala gre moji mentorici,izr. prof. dr. Ireni Ograjenšek za pomoč pri izdelavi magistrskega dela in za spodbudo pri delu, ter podjetju Engrotuš d.d. za vzorec podatkov.



IZJAVA O AVTORSTVU magistrskega dela

Podpisani/-a Anja Šostar, z vpisno številko 7400013, sem avtor/-ica magistrskega dela z naslovom: Povečevanje zvestobe kupcev z metodami podatkovnega rudarjenja.

S svojim podpisom zagotavljam, da:

- je predloženo magistrsko delo izključno rezultat mojega lastnega raziskovalnega dela;
- sem poskrbel/-a, da so dela in mnenja drugih avtorjev oz. avtoric, ki jih uporabljam v predloženem delu, navedena oz. citirana v skladu s fakultetnimi navodili;
- sem poskrbel/-a, da so vsa dela in mnenja drugih avtorjev oz. avtoric navedena v seznamu virov, ki je sestavni element predloženega dela in je zapisan v skladu s fakultetnimi navodili;
- sem pridobil/-a vsa dovoljenja za uporabo avtorskih del, ki so v celoti prenesena v predloženo delo in sem to tudi jasno zapisal/-a v predloženem delu;
- se zavedam, da je plagiatorstvo – predstavljanje tujih del, bodisi v obliki citata bodisi v obliki skoraj dobesednega parafraziranja bodisi v grafični obliki, s katerim so tuje misli oz. ideje predstavljene kot moje lastne – kaznivo po zakonu (Zakon o avtorski in sorodnih pravicah (UL RS, št. 16/07-UPB3, 68/08, 85/10 Skl.US: U-I-191/09-7, Up-916/09-16)), prekršek pa podleže tudi ukrepom Fakultete za družbene vede v skladu z njenimi pravili;
- se zavedam posledic, ki jih dokazano plagiatorstvo lahko predstavlja za predloženo delo in za moj status na Fakulteti za družbene vede;
- je elektronska oblika identična s tiskano obliko magistrskega dela ter soglašam z objavo magistrskega dela v zbirki »Dela FDV«.

V Ljubljani, dne 8. 6. 2016

Podpis avtorja/-ice: _____

Šostar

Povečevanje zvestobe kupcev z metodami podatkovnega rudarjenja

V magistrskem delu opredelim področje uporabe podatkovnega rudarjenja – kakšne probleme rešuje, kakšni so cilji podatkovnega rudarjenja ter kakšne tehnike podatkovnega rudarjenja so mi na voljo za reševanje specifičnega problema – za povečevanje zvestobe kupcev z metodami podatkovnega rudarjenja (z osredotočenostjo na nenadzorovano učenje: z omejitvijo na učenju povezovalnih pravil, segmentacije in izgradnje profilov kupcev). Vse skupaj povežem s primeri iz ciljanega trženja ter podam pregled prednosti in omejitev uporabe orodja za podatkovno rudarjenje v podjetjih (s poudarkom na trgovski dejavnosti).

V magistrski delu – ob podrobnejšem pregledu literature in praks v tujini, na poznavanju poslovnih potreb v podjetjih (s poudarkom na trgovcih) ter na podlagi rezultatov empiričnega raziskovanja – osnujem predlog modela, ki formalno opisuje in rešuje raziskovalni problem magistrske naloge – povečevanje zvestobe kupcev. Zvestoba kupcev je rezultat številnih dejavnikov (razvoj lastnih trgovskih blagovnih znamk, skrb za odnose s kupci, etično poslovno ravnanje, programi zvestobe, razumevanje kupcev ...), ki skupaj z zaupanjem in zadovoljstvom kupca vplivajo na to, ali bo določen kupec postal in ostal zvest trgovcu ali ne. Tako je danes strategija osredotočenosti na kupca in program zvestobe ne samo stvar mode, ampak pri trgovcih že stvar nuje.

S tem razlogom v magistrskem delu podrobneje obravnavam programe zvestobe (tako s vsebinskega, metodološkega kot etičnega vidika) ter opredelim oteževalne okoliščine s katerimi se trgovci srečujejo pri izvajanju strategije programa zvestobe (upoštevanje zakonskih predpisov na področju varovanja osebnih podatkov za potrebe: obdelave osebnih podatkov, segmentiranja, ciljanega trženja, spoštovanja kupčevih pravic ...). Največja prednost programov zvestobe je ogromna količina podatkov, ki omogoča odkrivanje znanja o kupcih in individualiziranje ponudbe njihovim željam in potrebam, na nivoju posameznega kupca. Pri analizi te ogromne količine zbranih podatkov, so trgovcu v veliko pomoč orodja za podatkovno rudarjenje. Izkoriščanje potenciala, ki ga nudi proces odkrivanja znanja v podatkih, omogoča trgovcu ohranjanje in povečevanje konkurenčne prednosti.

Uporabo podatkovnega rudarjenja predstavim na primeru trgovca Engrotuš d.d., s ciljem povečevanja zvestobe članov programa zvestobe Tuš kluba. Vir podatkov so relacijske podatkovne baze na vzorcu 7000 Tuš klub članov, z vsemi njihovimi nakupi znotraj trgovske in drogerijske dejavnosti za obdobje 12 mesecev. Pri samem procesu odkrivanja znanja v podatkih sledim CRISP-DM metodologiji ter zaključim s konkretnim modelom uporabe odkrivanja znanja v podjetju Engrotuš d.d..

Ključne besede: odkrivanje znanja v podatkih, podatkovno rudarjenje, povezovalna pravila, segmentacija, zvestoba kupcev.

Increasing customer loyalty with data mining methods

In the master thesis I define the scope of use of data mining – which problems it solves, what are the goals of data mining, and which techniques for solving specific problems are available – for increasing customer loyalty with data mining methods (focusing to unsupervised learning: with limitations on learning the association rules, segmentation and the customer profiling). The theory is substantiated by targeted marketing examples and an overview of advantages and limitations of the use of data mining tools in companies (with the emphasis on the retail sector).

In the thesis, based on thorough literature and international practice review and based on the knowledge of business needs in companies (with the emphasis on retail sector) and based on the results of empirical research, I founded a model which formally describes and solves the research problem of the thesis – the increase of customer loyalty. Customer loyalty is a result of numerous factors (development of own trademarks, care for customer relations, ethical business practice, loyalty programme, understanding customers, etc.), which, combined with customer trust and satisfaction influences whether a certain customer will become and remain loyal to a retailer or not. Therefore, customer centricity strategy and loyalty programme is not a matter of trend, but rather a matter of necessity for retailers.

For this reason the thesis examines loyalty programmes in detail (from substantial, methodological and ethic point of view) as well as the obstacles retailers face when implementing the customer loyalty strategy (consideration of data protection law for the purpose of personal data processing, segmentation, targeted marketing, respecting customer rights, etc.). The greatest advantage of loyalty programmes is a vast quantity of data, which enables knowledge discovery on customers and individualization of offer according to their desires and needs on a single customer level. For analysing this vast amount of gathered data retailers successfully use data mining tools. Exploiting the potential, offered by the process of knowledge discovery from databases enables the retailers to maintain and increase their competitive advantage.

I present the use of data mining on the case of retailer Engrotuš d.d., with the aim of increasing loyalty of the members of loyalty programme Tuš klub. The data source are relational databases on the sample of 7000 Tuš klub members, with all their purchases within the retail and drugstore activity for the period of 12 months. In the process of knowledge discovery from databases, I follow CRISP-DM methodology, and conclude with the use of a specific knowledge discovery model in the company Engrotuš d.d..

Key words: association rules, customer loyalty, data mining, knowledge discovery in databases, segmentation.

KAZALO VSEBINE

1 UVOD	9
1.1 OPREDELITEV PROBLEMATIKE IN PODROČJA MAGISTRSKEGA DELA.....	9
1.2 NAMEN, CILJI IN RAZISKOVALNA VPRAŠANJA	11
1.3 METODOLOGIJA	13
1.4 VSEBINSKA OPREDELITEV MAGISTRSKEGA DELA	14
2 TEORETIČNA IZHODIŠČA	16
2.1 OPREDELITEV TRGOVINE IN KUPCEV	16
2.2 TRGOVSKE BLAGOVNE ZNAMKE.....	17
2.3 TRŽENJE V TRGOVINI	18
2.4 UPRAVLJANJE ODNOSOV S KUPCI IN OSREDOTOČENOST NA KUPCA.....	19
POVZETEK	22
3 ZVESTOBA KUPCEV.....	24
3.1 OPREDELITEV ZVESTOBE	24
3.2 ODNOS MED ZADOVOLJSTVOM IN ZVESTOBO	26
3.3 PROGRAM ZVESTOBE	27
3.3.1 Varstvo osebnih podatkov v kontekstu programa zvestobe	30
3.3.2 Pravice kupcev	32
POVZETEK	33
4 PODATKOVNO RUDARJENJE	35
4.1 PODATKI IN ZNANJE (V KONTEKSTU VIROV ZA PODATKOVNO RUDARJENJE).....	35
4.2 OPREDELITEV ODKRIVANJA ZNANJA V PODATKIH, PODATKOVNEGA RUDARJENJA IN STROJNEGA UČENJA	38
4.3 PROCES ODKRIVANJA ZNANJA V PODATKIH	39
4.4 PRIPRAVA PODATKOV ZA PODATKOVNO RUDARJENJE	42
4.5 CILJI IN NALOGE PODATKOVNEGA RUDARJENJA	43
4.6 TEHNIKE PODATKOVNEGA RUDARJENJA	47
4.7 ODKRIVANJE ZNANJA V POSLOVNEM OKOLJU	53
4.7.1 Odkrivanje znanja v poslovnem okolju trgovca – v okviru programa zvestobe	54
4.7.2 Uporaba podatkovnega rudarjenja v podjetjih: prednosti in omejitve	57
4.8 PRIMERI RAZISKAV (IZ POSLOVNEGA OKOLJA) V SLOVENSKEM PROSTORU	61
POVZETEK	64

5	EKSPERIMENTI IN REZULTATI	65
5.1	OPIS RAZISKOVALNEGA PROBLEMA	65
5.1.1	<i>Odkrivanje znanja v okviru programa zvestobe »Tuš klub«</i>	66
5.2	OPIS IN RAZUMEVANJE PODATKOV	67
5.2.1	<i>Podatkovni model.....</i>	68
5.2.2	<i>Priprava podatkov.....</i>	69
5.3	OSNOVNE STATISTIKE IN ANALIZE	71
5.4	OPIS VZORCA	73
5.5	IZGRADNJA TAKTIČNIH SEGMENTOV KUPCEV	74
5.5.1	<i>Povezava segmentov s statističnimi kazalniki po regijah.....</i>	75
5.5.2	<i>Dodatna obogatitev profila segmentov z vsemi razpoložljivimi podatki.....</i>	77
5.5.3	<i>Evalvacija segmentov.....</i>	81
5.6	ANALIZA NAKUPNE KOŠARICE.....	82
5.6.1	<i>Število artiklov v košaricah.....</i>	84
5.6.2	<i>Povezovalna pravila.....</i>	84
5.6.3	<i>Priporočila artiklov.....</i>	91
5.6.4	<i>Evalvacija povezovalnih pravil.....</i>	95
5.7	UPORABA ODKRITEGA ZNANJA NA PRIMERU TRGOVCA TUŠ.....	96
6	PREDLOG MODELA ZA POVEČEVANJE ZVESTOBE KUPCEV	97
7	ZAKLJUČEK	103
8	LITERATURA.....	109
PRILOGE	120	
	PRILOGA A: SEZNAM UPORABLJENIH KRATIC IN SIMBOLOV	120
	PRILOGA B: PROFIL TAKTIČNIH SEGMENTOV KUPCEV	121
	PRILOGA C: PRIMERI POVEZOVALNIH PRAVIL	129
	PRILOGA Č: ARTIKLI, KI SE POGOSTO POJAVLJAJO SKUPAJ V NAKUPNI KOŠARICI.....	130
	PRILOGA D: PRIMER PERSONALIZIRANE DIREKTNE POŠTE TRGOVCA TUŠ V LETU 2016	131
	PRILOGA E: PRIPOROČILA ARTIKLOV ZA PRIMER PERSONALIZIRANE DIREKTNE POŠTE	133
	PRILOGA F: POTROŠNIŠKI TRENDI ZA LETO 2016.....	136

KAZALO SLIK

Slika 2.1: Poenostavljen prikaz spreminjanja kulture podjetja.....	20
Slika 4.1: Shema CRISP-DM metodologije.....	40
Slika 4.2: Definicija podpore, zaupanja in izboljšave.....	50
Slika 5.1: Struktura podatkovnega modela za potrebe magistrskega dela.....	68
Slika 5.2: Porazdelitev TK kartic na TK člane.....	72
Slika 5.3: Porazdelitev števila nakupov na TK člana za obdobje 12 mesecev.....	72
Slika 5.4: Porazdelitev števila artiklov na TK člana za obdobje 12 mesecev.....	72
Slika 5.5: Vzorec 6977 TK članov po demografskih značilnostih.....	73
Slika 5.6: Vzorec 6977 TK članov po dovoljenjih za kontaktiranje.....	73
Slika 5.7: Porazdelitev števila artiklov v košarici.....	84
Slika 5.8: Prikaz padanja podpore in števila ustvarjenih pravil glede na razpršenost podatkov na 441415 nakupnih košaricah.....	85
Slika 5.9: Kupon 50 % na mehčalce perila SILAN.....	91
Slika 5.10: Kupon 30 % na detergente za ročno pomivanje posode PRIL.....	93
Slika 5.11: Kupon 50 % na pralne praške REX, kupon 40 % na pralne praške PERSIL in kupon 30 % popust na detergente za občutljivo perilo PERWOLL.....	94
Slika 5.12: Predlagan konkretni model uporabe odkrivanja znanja v podjetju Engrotuš d.d.....	96
Slika 6.1: Shema zgrajenega teoretičnega modela za povečevanje zvestobe kupcev na primeru poslovnega okolja trgovca.....	97

KAZALO TABEL

Tabela 4.1: Hiter pregled najpogostejših tehnik podatkovnega rudarjenja.....	47
Tabela 4.2: Poenostavljen primer nakupne košarice.....	50
Tabela 5.1: Povezava segmentov s statističnimi kazalniki po statističnih regijah.....	76
Tabela 5.2: Prikaz razlike v profilu segmentov po izbranih atributih glede na celoten vzorec TK članov.....	80
Tabela 5.3: Obrazložitev taksonomije blagovnih skupin na primeru 495287 nakupnih košaric.....	82
Tabela 5.4: Osnovne statistike modela APriori (Po 1 %; Za 25 %) na treh podatkovnih množicah.....	90
Tabela 5.5: Primer priporočil za blagovno skupino MEHČALCI PERILA.....	92
Tabela 5.6: Primer priporočil za blagovno skupino DETERGENTI ZA ROČNO POMIVANJE POSODE.....	93
Tabela 5.7: Primer priporočil za blagovno skupino PRALNI PRAŠKI ter DETERGENTI ZA OBČUTLJIVO PERILO.....	94

1 UVOD

»Utapljamo se v podatkih, vendar stradamo za znanjem.«

dr. Aleksander Pivk

1.1 Opredelitev problematike in področja magistrskega dela

Trgovci se za pridobivanje informacij o vedenju kupcev zelo pogosto poslužujejo tržnih raziskav (anketiranje, intervjuji) in le-te imajo ključno vlogo pri zagotavljanju dolgoročnega razvoja podjetja in predstavljajo temelj za uresničevanje strategije »osredotočenost na kupca«. V središče se torej postavlja kupec, ki ima hkrati vedno večjo moč, njegove nakupne navade se vse hitreje spreminjajo ter ogromna možnost izbire (povečana konkurenca tako na lokalnem kot globalnem trgu), so dejavniki, da se podjetja vse bolj osredotočajo na segment zvestih kupcev. Poznavanje zvestih kupcev in orodij za povečevanje zvestobe, tako postaja eden glavnih elementov za uspešnost podjetja na trgu (Nguyen in Klaus 2013; Vukasović 2013; Ho in drugi 2015).

Zvestoba kupca določenemu trgovcu (ali navsezadnje kateremu koli podjetju) nikakor ni samoumevna. Trditvi: »*Enkrat zvesta stranka, vedno zvesta stranka.*«, »*Večina strank si želi biti zvesta – stranke želijo odnos s podjetji, s katerimi poslujejo.*«, sta le dve izmed številnih mitov o zvestobi (Keiningham in drugi 2005). Trgovci se tako, za povečevanje zvestobe, vedno bolj poslužujejo orodij ciljanega trženja (direktna pošta, personalizirani kuponi in popusti, zbiranje točk, zbiranje odstotka vrednosti nakupa, zahvala za nakup, itd.), katerih temelj so programi zvestobe. Na kartici programa zvestobe se namreč zbirajo kontaktni podatki o kupcu, pri večjih trgovcih pa dodatno še celotna nakupna zgodovina. Osnovni cilj programov zvestobe je ustvarjanje ponakupov (večanje števila in vrednosti nakupov) in večanje števila zvestih kupcev (Sharp in Sharp 1997; Liu 2007), vendar je lahko učinek tudi nasproten – upad zvestih kupcev (Bagdonienė in Jakštaitė 2007; Musek Lešnik 2008; Nguyen in Klaus 2013; Stoeckl in Luedicke 2015; Steinhoff in Palmatier 2016) v primeru velikega razkoraka med obstoječim stanjem in strategijo programa zvestobe (npr. neetična ravnanja).

Hiter razvoj informacijske in telekomunikacijske tehnologije, ki odpira tudi vedno nove možnosti v ciljanem trženju, kliče po uvedbi novih načinov za pridobivanje znanja o kupcih – podatki o kupcih še nikoli niso bili tako pomembni kot so danes (Jai in King 2016; 296). S sistematičnim zbiranjem podatkov (ki so shranjeni v različnih podatkovnih bazah), se količina zbranih podatkov nenehno povečuje, pri čemer trgovci nad njimi v večini izvajajo le preproste statistične obdelave. Tako se skrito znanje (npr. zanimive povezave med izdelki in njihovimi kupci) pogosto zanemarja (Avdičaušević in drugi 2002).

Proces odkrivanja novega znanja mora potekati brez prevelikega človeškega napora. Jedro sistema za avtomatsko odkrivanje znanja predstavlja inteligentni sistem, ki iz organiziranih podatkov odkriva novo, uporabniku zanimivo znanje (Avdičaušević in drugi 2002, 35). Ta problem rešujejo metode inteligentnih sistemov, ki jih uporabljamo tudi na področju podatkovnega rudarjenja. Tako smo prišli do opredelitve problematike magistrske naloge – povečevanje zvestobe kupcev z metodami podatkovnega rudarjenja.

Če želim uspešno reševati problem povečevanja zvestobe z metodami podatkovnega rudarjenja, moram vedeti, kaj podatkovno rudarjenje zmore in česa ne, kakšne probleme rešuje, kakšni so cilji podatkovnega rudarjenja, kakšne tehnike podatkovnega rudarjenja so mi na voljo za reševanje specifičnega problema in zelo pomembno, kako pripraviti zbrane podatke, da jih lahko obdelujem s podatkovnim rudarjenjem.

Ključno raziskovalno vprašanje, ki ga rešujem v magistrskem delu je, kako ogromno količino zbranih podatkov (o kupcih in zgodovini njihovih nakupov) obvladati in učinkovito pretvoriti v uporabno znanje za povečevanje zvestobe kupcev. Trgovci se namreč utapljujejo v podatkih, a hkrati stradajo za znanjem.

V magistrskem delu tako raziskujem, kako izluščiti znanje iz – v okviru programa zvestobe kupcev – zbranih podatkov, ki jih lahko klasificiram v dve skupini, in sicer: transakcijski podatki (podatki na računu: čas nakupa, kraj nakupa, kupljeni izdelki, cena izdelkov ...) in demografski podatki (podatki o kupcih: v konkretnem primeru bom analizirala kupce trgovca Engrotuš d.d. – člane programa zvestobe Tuš kluba). Nekateri trgovci imajo na nivoju kupca zbrane tudi podatke iz raziskav zadovoljstva, t.i. tretja skupina podatkov v okviru programa zvestobe (Ograjenšek in Žabkar 2010, 135).

Magistrsko delo se torej osredotoča na reševanje problema povečevanja zvestobe kupcev (osnovna teoretična referenca: Sharp in Sharp 1997; Potočnik 2001; Griffin 2002; Ograjenšek 2003; Keiningham in drugi 2005; Kumar in Reinartz 2006; Liu 2007; Musek Lešnik 2008; Ograjenšek in Žabkar 2010; Sällberg 2010; Možina in drugi 2012; Martoz-Partal in González-Benito 2013; Vukasović 2013; Koschate-Fischer in drugi 2014; Kushwaha 2014; Renko in Družijanić 2014; Ho in drugi 2015; Pleshko in Heiens 2015; Radder in drugi 2015; Seenivasan in drugi 2015; Snoj in Gabrijan 2015; Stoeckl in Luedicke 2015; do Vale in drugi 2016; Jai in King 2016; Steinhoff in Palmatier 2016; Verma in drugi 2016 ...), z metodami podatkovnega rudarjenja (osnovna teoretična referenca: Agrawal in drugi 1993; Agrawal in Srikant 1994; Fayyad in drugi 1996; Fayyad in drugi 1996a; Fayyad in drugi 1996b; Berry in Linoff 1997; Fayyad in drugi 2002; Mladenović in drugi 2003; Witten in Frank 2005; Kononenko 2005; Tan in drugi 2006; Kononenko in Kukar 2007; Raeder in Chawla 2011 ...). Za doseg cilja, sem v magistrskem delu preučila tudi področje priprave podatkov (osnovna teoretična referenca: Pyle 1999), ki je nujno potrebno za nadaljnjo analizo podatkov z uporabo metod podatkovnega rudarjenja. Proces priprave podatkov lahko vzame tudi do 90 % celotnega časa namenjenega za cikel podatkovnega rudarjenja. Na transformiranih podatkih sem nato izvedla metode podatkovnega rudarjenja, ki so lahko pomembno orodje za povečevanje zvestobe kupcev. Osrednja teoretična tematika magistrskega dela je celovit pregled področja zvestobe kupcev in podatkovnega rudarjenja.

1.2 Namen, cilji in raziskovalna vprašanja

Namen magistrskega dela je opredeliti metode in tehnike podatkovnega rudarjenja ter se usposobiti za reševanje problemov analize podatkov na področju ciljanega trženja, s ciljem povečevanja zvestobe kupcev, ter pridobljeno znanje uporabiti v praksi.

Cilji v teoretičnem delu magistrskega dela so naslednji:

- Na osnovi teoretičnih spoznanj opredeliti pojme: trgovina, trženje v trgovini, ciljano trženje, odnosi s kupci, osredotočenost na kupca, zvestobe kupcev.
- Na osnovi teoretičnih spoznanj opredeliti pojme: podatkovno rudarjenje, odkrivanje zakonitosti ter znanja v podatkih, strojno učenje, povezovalna pravila, izdelava profilov kupcev, segmentacija, vizualizacija podatkov.

- S pomočjo literature čim bolj spoznati in razumeti proces podatkovnega rudarjenja.

Cilji v empiričnem delu magistrskega dela so naslednji:

- Opis podatkov, priprava podatkov, obdelava podatkov ter analiza podatkov v statističnem orodju IBM SPSS MODELER 17.0 ter analiza rezultatov.
- Izgradnja povezovalnih pravil.
- Izgradnja taktičnih segmentov kupcev.
- Ocena primernosti modela.

Praktični cilji magistrskega dela so naslednji:

- Predstavitev pridobljenega znanja in rezultatov magistrskega dela v podjetju Engrotuš d.d..
- Predstavitev primera uporabe pridobljenega znanja v podjetju Studio Moderna d.o.o..

Iz zastavljenih raziskovalnih ciljev izhajajo naslednja raziskovalna vprašanja:

- Kako iz ogromne količine podatkov izluščiti znanje?
- Kako pripraviti podatke, da lahko nad njimi izvajam podatkovno rudarjenje?
- Ali lahko z metodami podatkovnega rudarjenja povečujemo zvestobo kupcev?
- Ali lahko v ogromni količini transakcijskih podatkov najdem povezovalna pravila na najnižjem nivoju (izdelek) z minimalno zahtevano stopnjo podpore in zaupanja ter, da so hkrati dovolj zanimiva oziroma informativna? Ali pa bodo v mojem primeru povezovalna pravila boljša na višjem nivoju (blagovna skupina), kjer je razpršenost podatkov manjša? Ali lahko večnivojska povezovalna pravila nadgradim z večdimenzionalnimi povezovalnimi pravili, npr. dodam podatek o spolu, starosti, regiji?
- Katere izdelke večja množica kupcev pogosto kupuje skupaj?
- Ali znam poiskati izdelke, da bo odziv na ciljano trženje največji?

V magistrskem delu sem se osredotočila predvsem na nenadzorovano učenje (z omejitvijo na učenju povezovalnih pravil, segmentacije in izgradnje profilov kupcev) in na rešitve za povečevanje zvestobe kupcev.

1.3 Metodologija

Pri pisanju magistrskega dela sem uporabila strokovno literaturo domačih in tujih avtorjev, prispevke in članke ter druge vire, kot so objave tujih in domačih del na spletnih straneh, ki obravnavajo tematiko zvestobe kupcev. Teoretični del sem nadaljevala s proučevanjem literature o procesu, metodah in tehnikah podatkovnega rudarjenja. Proučiti (raziskati) je bilo potrebno obstoječo prakso v gospodarstvu (poudarek na področju trgovinske dejavnosti na domačem in tujem trgu) na področju izboljševanja zvestobe kupcev (z osredotočenostjo na ciljano trženje).

Ob podrobnejšem pregledu literature in praks v tujini in poznavanju poslovnih potreb v podjetjih, sem na osnovi empiričnega raziskovanja izdelala teoretični model, ki formalno opisuje in rešuje raziskovalni problem (povečevanje zvestobe). Izdelan model, je v mojem primeru posledica množice empiričnih eksperimentov – izdelala sem ga torej na podlagi rezultatov empiričnega raziskovanja ter na podlagi proučene literature. Vir podatkov (so last podjetja Engrotuš d.d. in niso javno dostopni) za empirični del magistrskega dela, so relacijske podatkovne baze (tabela z vsemi transakcijskimi podatki: čas nakupa, poslovalnica nakupa, izdelki na računu, cena izdelkov, tip akcije ...; tabele s podatki, ki se zbirajo na Tuš klub kartici: demografski podatki; šifrant izdelkov: izdelki in pripadajoče blagovne skupine; šifrant poslovalnic). Uporabljena metodologija je torej učenje iz relacijskih podatkovnih baz. Za potrebe magistrskega dela sem dobila od podjetja Engrotuš d.d. vzorec 7000 kupcev (Tuš klub članov), z vsemi pripadajočimi nakupi za obdobje 12 mesecev. Ogromna količina podatkov mi omogoča, da z metodami podatkovnega rudarjenja odkrivam ogromno količino novega znanja o kupcih (nakupno obnašanje, segmentacija, odzivnost na akcije ...), kar mi dodatno omogoča eksperimentiranje tudi z različnimi modeli. Največji poudarek je na metodi povezovalnih pravil (angl. »*associations rules*«), ki so se prvič pojavila prav v trgovski dejavnosti, za analizo nakupovalnih košaric. Povezovalna pravila so zelo uporabna v poslovnem svetu, saj so intuitivno razumljiva in jih je moč predstaviti vodstvu podjetja, kar je tudi največja moč tehnike.

Eksperimente rudarjenja sem torej izvajala na več načinov, z uporabo več pristopov in več tehnik za reševanje raziskovalnega problema. Uspeh ni odvisen samo od pristopa rudarjenja, temveč tudi od oblikovanja problema (problem imam zelo jasno oblikovan) in ustreznega

človeškega znanja. Pri empiričnem delu sem sledila CRISP-DM metodologiji (Chapman in drugi 2000), ki mi je pomagala pri samih postopkih priprave in izvedbe podatkovnega rudarjenja (za katero so temelje postavila podjetja SPSS, NCR ter DaimlerChrysler; alternativa je SEMMA metodologija, ki je nastala pod okriljem SAS Inštituta). Za analizo podatkov sem uporabila orodje IBM SPSS MODELER. Na koncu strnem rezultate, podam ugotovitve, opišem učinek rezultatov magistrskega dela na podjetja ter podam predloge izboljšav in rešitev pri povečevanju zvestobe kupcev.

Magistrsko delo je rezultat samostojnega raziskovalnega dela. Podatki iz realnega poslovnega okolja predstavljajo ključno omejitev magistrskega dela, saj zaradi poslovne skrivnosti onemogočajo razkritje občutljivih informacij.

1.4 Vsebinska opredelitev magistrskega dela

Magistrsko delo je razdeljeno na 7 vsebinskih sklopov. V nadaljevanju magistrskega dela v drugem poglavju na splošno opredelim pojme v povezavi s trgovino in kupci ter podrobneje obravnavam tri dejavnike, ki pomembno vplivajo na konkurenčno prednost trgovca: razvoj lastnih trgovskih blagovnih znamk, trženjsko komuniciranje (s poudarkom na ciljanem trženju) ter upravljanje odnosov s kupci in dosledno izvajanje strategije osredotočenosti na kupca.

Tretje poglavje je teoretični del, vezan na zvestobo kupcev. V njem opredelim pojem zvestobe kupcev, odnos med zadovoljstvom in zvestobo kupcev, pomen ohranjanja zvestobe kupcev za trgovca ter podrobneje opredelim programe zvestobe (tako z vsebinskega, metodološkega kot etičnega vidika). Poglavje zaključim z opredelitvijo oteževalnih okoliščin, s katerimi se srečujejo trgovci pri izvajanju strategije programa zvestobe.

Sledi četrto poglavje v katerem opredelim pojme, ki so zelo tesno povezani s podatkovnim rudarjenjem: proces odkrivanja znanja v podatkih, podatkovno rudarjenje, strojno učenje, vizualizacija, CRISP-DM metodologija. Podrobneje orišem področje uporabe podatkovnega rudarjenja – kakšne probleme rešuje, kakšni so cilji podatkovnega rudarjenja ter kakšne tehnike podatkovnega rudarjenja so mi na voljo za reševanje specifičnega problema. Vse skupaj povežem s primeri iz ciljanega trženja ter podam pregled prednosti in omejitev

uporabe orodja za podatkovno rudarjenje v podjetjih (s poudarkom na trgovski dejavnosti). Četrto poglavje zaključim s pregledom nekaterih raziskav na tem področju v slovenskem okolju.

Peto poglavje predstavlja empirični del magistrske naloge. V njem konkretno predstavim uporabo metod podatkovnega rudarjenja na vzorcu podatkov članov programa zvestobe Tuš kluba (trgovca Engrotuš d.d.), za povečevanje zvestobe kupcev. Podam opis podatkov, kratek opis procesa priprave podatkov, pregled rezultatov ter poglavje zaključim s konkretnim modelom uporabe procesa odkrivanja znanja v podjetju Engrotuš d.d..

Sledi šesto poglavje, v katerem ob podrobnejšem pregledu literature in praks v tujini, na poznavanju poslovnih potreb v podjetjih (s poudarkom na trgovcih) ter na podlagi rezultatov empiričnega raziskovanja izdelam teoretični model, ki formalno opisuje in rešuje raziskovalni problem magistrske naloge – povečevanje zvestobe kupcev. Vzporedno z interpretacijo modela v tem poglavju podam tudi predloge izboljšav in rešitev pri povečevanju zvestobe kupcev.

Magistrsko delo zaključim s sedmim poglavjem, v katerem na kratko povzamem vsebino magistrske naloge, podam zaključke ter opredelim izzive za nadaljnjo raziskovanje.

2 TEORETIČNA IZHODIŠČA

»Vaš najpomembnejši potencial so vaši kupci – z naslovi in najpomembnejšimi poslovnimi podatki. Čuvajte jih kot zaklad.«

Edgar K. Geffroy

Drugo poglavje predstavlja prvi teoretični sklop, v katerem podam splošne opredelitve pojmov v povezavi s trgovino in kupci ter podrobneje obravnavam tri dejavnike, ki pomembno vplivajo na konkurenčno prednost trgovca: razvoj trgovskih blagovnih znamk, trženjsko komuniciranje (s poudarkom na ciljanem trženju) ter upravljanje odnosov s kupci in dosledno izvajanje strategije osredotočenosti na kupca.

2.1 Opredelitev trgovine in kupcev

Trgovinska prodaja v obliki maloprodaje oziroma trgovina na drobno (angl. »*retailing*«) je niz poslovnih aktivnosti, ki ustvarjajo dodano vrednost izdelkom in storitvam, ki se prodajajo končnim kupcem za njihovo osebno ali skupno (npr. družinsko) rabo (Kotler 2004, 535; Levy in Weitz 2012, 6). V magistrskem delu se omejujem izključno na poslovno okolje trgovine na drobno, krajše uporabljam izraz »trgovec«.

Kupca (v literaturi se uporabljajo tudi izrazi porabnik, potrošnik, nakupovalec) opredelim kot: oseba, ki ima možnost (sredstva in sposobnost) za nakup in, ki kupuje izdelke in storitve pri trgovcu s namenom, da zadovolji osebne ali skupne (npr. družinske) interese (Možina in drugi 2012, 58; Vukasović 2013, 30–31).

2.2 Trgovske blagovne znamke

Pomemben razlog za vračanje kupcev je čustvena navezanost/predanost na trgovske blagovne znamke – subjektivni občutek pripadnosti povečuje trdnost odnosa med kupcem in trgovcem (Musek Lešnik 2008). Trgovci razvijajo lastne blagovne znamke in skrbijo za njihovo trajnost, saj jim zagotavljajo dolgoročno zvestobo kupcev (Damjan in Možina 1998; Potočnik 2001; Martoz-Partal in González-Benito 2013; Koschate-Fischer in drugi 2014; Seenivasan in drugi 2015; do Vale in drugi 2016).

Blagovna znamka je ime, izraz, simbol, oblika ali kombinacija naštetih lastnosti, namenjena prepoznavanju izdelkov/storitev enega ali skupine trgovcev ter razlikovanju njihovih izdelkov/storitev od konkurenčnih (Potočnik 2001, 228; Kotler 2004, 418). Trgovec lahko prodaja izdelek z blagovno znamko proizvajalca, lastno blagovno znamko oziroma blagovno znamko trgovca ali z licenčno blagovno znamko. Čeprav še vedno prevladujejo blagovne znamke proizvajalcev, veliki trgovci čedalje hitreje razvijajo lastne blagovne znamke – z njimi se trgovci identificirajo oziroma predstavljajo pomemben diferenciator med trgovcem in konkurenco (Nies in Natter 2012; Koschate-Fischer in drugi 2014; Cuneo in drugi 2015; Seenivasan in drugi 2015; do Vale in drugi 2016). Mednarodne trgovske korporacije ustvarijo do 23 % vseh prihodkov z lastnimi blagovnimi znamkami (Cuneo in drugi 2015). Trgovske blagovne znamke so najbolj razvite v Zahodni Evropi in Severni Ameriki – najbolj razvit trg trgovskih blagovnih znamk ima Švica, kjer ti izdelki tvorijo kar 38 % v skupnem tržnem deležu (Euromonitor International 2014). Na razvitem trgu so trgovske blagovne znamke postale sestavni del nakupne košarice, saj po Euromonitorjevi raziskavi *Global Consumer Trends Survey 2013* več kot 89 % kupcev občasno kupuje tudi izdelke trgovskih blagovnih znamk (Euromonitor International 2014).

Osnovni pogoj za pripadnost blagovni znamki je zaupanje v obljubo trgovca, da bo dosledno zagotavljal določene lastnosti oziroma stalno kakovost izdelkov (Potočnik 2001; Steenkamp in drugi 2010; Nies in Natter 2012; Martoz-Partal in González-Benito 2013; Seenivasan in drugi 2015). Pomemben dejavnik zaupanja je tudi kupčeva subjektivna ocena »vrednosti«, ki jo dobi s strani trgovke blagovne znamke. Če za svoj denar dobi zadostno »vrednost« ali celo več kot bi dobil drugod, se bo bolj pogosto vračal (Musek Lešnik 2008; Nies in Natter 2012; Nguyen in Klaus 2013).

2.3 Trženje v trgovini

Pod pojmom trženjsko komuniciranje (Smith in Taylor v Žabkar in Zbačnik 2009, 50) se razumejo vse aktivnosti trgovca, s katerimi sporoča zaposlenim, kupcem in okolju o svoji ponudbi na trgu: oglaševanje, osebna prodaja, pospeševanje prodaje, odnose z javnostmi, ciljano trženje kot tudi sponzoriranje, razstave, embalaža, oprema prodajnih mest ... Pri čemer je zadovoljstvo in zvestoba kupcev v središču tržnega načina razmišljanja (Vukasović 2013; Nguyen in Klaus 2013; Ho in drugi 2015).

Z namenom povečevanja zadovoljstva in zvestobe kupcev morajo trgovci upoštevati pristop t.i. ciljanega trženja (angl. »*targeted marketing*«), ki je sestavljen iz treh korakov:

- (1) segmentacije – opredelitev ciljnih segmentov kupcev, ki imajo določene skupne lastnosti;
- (2) pozicioniranja – za vsak izbrani ciljni segment kupcev trgovec razvije tržno ponudbo, ki je za ciljni segment edinstvena v primerjavi s konkurenčnimi ponodbami¹ (drugih segmentov) oziroma prilagoditev ponudbe izbranemu ciljnemu segmentu kupcev;
- (3) ciljanja – trženjsko komuniciranje (na izbran ciljni segment kupcev s prilagojeno ponudbo).

Ekstremni primer ciljanega trženja je individualizirano trženje (angl. »*one-to-one marketing*«), ki je prilagojen posameznemu kupcu. Cilj individualnega trženja je torej čim bolj natančno prilagoditi ponudbo posameznemu kupcu (Pitta 1998; Fowler in Pitta 2013). Po mnenju nekaterih je bilo ciljano trženje ena najpomembnejših novih idej na področju trženjskega komuniciranja ob koncu dvajsetega stoletja (Snoj in Gabrijan 2015) – le prilagojena ponudba na mikrosegmente lahko prinese konkurenčno prednost trgovcu (Kushwaha 2014). S ciljanim trženjem, podprtim na podlagi podatkovnih baz/podatkov (angl. »*data driven marketing*«) oziroma znanja o kupcih, trgovec zadovolji potrebe in želje kupcev in si tako ustvarja konkurenčno prednost (Jentzsch in drugi 2013; Ho in drugi 2015).

Vsak trgovec mora sam opredeliti lastne vire za oblikovanje konkurenčne prednosti in diferenciacije na trgu. Trženjska strategija je kot taka most med razumevanjem trgovine na drobno, taktičnim upravljanjem s sortimentom in prodajnimi aktivnostmi (Levy in Weitz

¹ Postopek oblikovanja takšne ponudbe imenujem pozicioniranje (po Vukasović 2013).

2012, 111). Vizija trženjske strategije vsakega večjega trgovca bi morala biti trajnostna in edinstvena konkurenčna prednost, ki z aktivnostmi (ki to strategijo oblikujejo) predstavlja ključ do finančne uspešnosti. Pomen trženjske strategije se kaže skozi vpliv na zaznavanje in razumevanje trženjskih aktivnosti pri kupcih (Žabkar in Zbačnik 2009; Naghiu 2011). Glasna in všečna ponudba ni dovolj (Stoeckl in Luedicke 2015). Trgovci zapravljajo velike vsote za trženjske pristope, ki ne pomenijo nič, ker jih kupci ne sprejmejo. Skrivnostna formula je seštevek zmožnosti trgovca: da proda ne samo izdelke in storitve, ampak predvsem svojo zgodbo; za prekinitvev zmotnega prepričanja, da ima vzpostavljen odnos z vsemi kupci, ki se vračajo (ponavljajoče nakupe zaradi bližine, cene in drugih ne-čustvenih povodov je potrebno ločiti od vračanja zaradi posebnega odnosa, ki temelji na občutku pripadnosti); razvoj globljega odnosa do kupca in kupca do trgovca (Musek Lešnik 2007; Naghiu 2011²).

Musek Lešnik (2007, 60) opozarja, da je skrb za odnose s kupci pomembno varovalo pred njihovim »begom« drugam. Sistematično upravljanje odnosov s kupci, je pri mnogih podjetjih (posebej trgovcih) področje najširšega manevrskega prostora za izboljšanje poslovnih rezultatov, je ključ poslovnega uspeha in celo preživetja (Albrecht 1995; Musek Lešnik 2007; Musek Lešnik 2008; Sheth in drugi 2011; Khodakarami in Chan 2014; Kushwaha 2014; Ho in drugi 2015). Več o strategiji osredotočenosti na kupca v naslednjem podpoglavju.

2.4 Upravljanje odnosov s kupci in osredotočenost na kupca

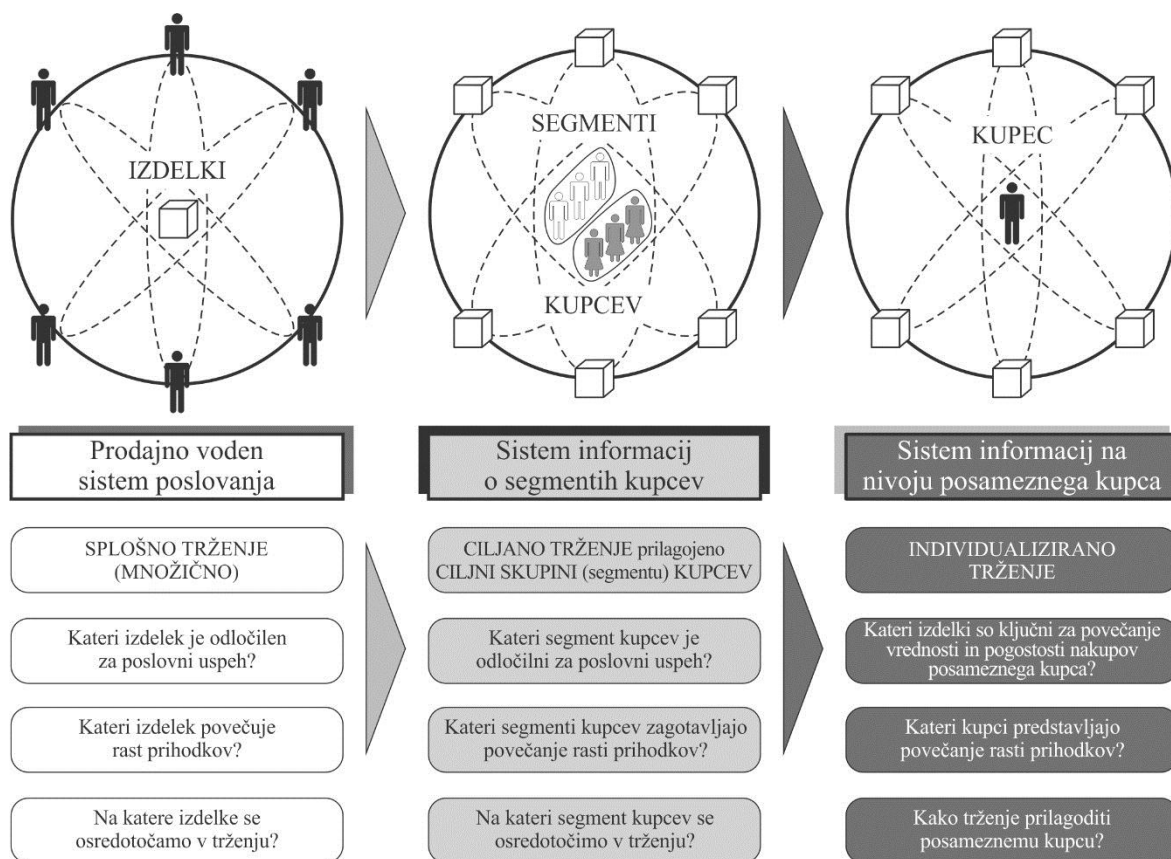
Kot je zapisal Geffroy (1996, 9) leta 1996: »Časi se spreminjajo – spreminjajo pa se tako hitro, da jih komaj dohitevamo,« velja še danes – predvsem za trgovce, ki se morajo prilagajati vse bolj zahtevnemu kupcu. Kupec prihodnosti, kot ga definira Geffroy (1996), je danes realnost. Kupec danes hoče sooblikovati izdelke, hoče prispevati svoje izkušnje, hoče dialog, ne mara manipuliranja, je vse bolj izkušen/informiran in predvsem že velikokrat prevaran. Pri trgovcu hoče biti identificiran, torej prepoznan kot kupec in želi si njemu

² Gradnja dolgoročnega globljega odnosa do stranke, podjetju zagotavlja konkurenčno prednost, ki je ne more kopirati konkurenca (to velja za vsa podjetja, tudi za trgovce). Naghiu v pričujočem znanstvenem članku dokazuje, ne samo da lahko podjetje psihološke dejavnike strank nadzoruje in usmerja skozi trženje aktivnosti, temveč tudi da so psihološki dejavniki v veliki meri odgovorni za uspeh ali neuspeh trženjskih aktivnosti, zato je ključnega pomena, da se upoštevajo v trženjski strategiji podjetja.

prilagojeno ponudbo (Geffroy 1996; Griffin 2002; Kushwaha 2014; Radder in drugi 2015; Verma in drugi 2016³).

Vse to od trgovcev zahteva, da je danes kupec tisti, ki je v središču poslovanja (t.i. strategija osredotočenosti na kupca, angl. »customer centricity«), vpeljan celovit in integriran sistem upravljanja odnosov kupcev (angl. »CRM – customer relationship management«) pa eden od glavnih ciljev trgovcev (Wulf in drugi 2003; Šmid 2004; Khodakarami in Chan 2014⁴; Kushwaha 2014; Ho in drugi 2015). Prehod od »marketinške kratkovidnosti«⁵ (ang. »marketing myopia«, pojem za vse trženjske aktivnosti kjer se zanemari vidik kupca), kjer je v ospredju izdelek do ciljanega trženja prilagojenega ciljni skupini/segmentu, kjer je v ospredju kupec, do ekstremne oblike individualiziranega trženja, kjer je ponudba prilagojena posameznemu kupcu, prikazuje spodnja slika (glej sliko 2.1).

Slika 2.1: Poenostavljen prikaz spreminjanja kulture podjetja.



³ Avtorji v članku preverjajo ali osnovni koncepti strategije osredotočenosti na kupca veljajo tudi za spletno trgovino, ena od ugotovitev je, da zadovoljstvo z odnosom (kupec-trgovec) pozitivno kolerira z zvestobo.

⁴ V članku avtorja posebej poudarjata pomen pobiranja podatkov in odkrivanja znanja o kupcih za trgovca.

⁵ Pojem je opredelil Levitt leta 1960 v legendarnem članku »Marketing myopia« (Snoj in Gabrijan 2015).

Če želi trgovec uspešno spodbujati vračanje kupcev, mora strategija osredotočenosti na kupca zajeti celo podjetje. Še več, skrb za kupce se mora iz zapisov in deklarativnih izjav prenesti v vsakdanjo prakso. Kupci morajo začititi, da trgovec njihove interese resnično postavlja v ospredje. Zato so s strani trgovca potrebne naslednje strateške aktivnosti (povzeto po Peppers in Rogers v Kotler 2004; Musek Lešnik 2007; Naghiu 2011):

- opredelitev ciljne skupine kupcev ter merjenje vračanja kupcev,
- iskanje zvestobe na pravih mestih in med »pravimi« kupci (trgovci bi morali več truda vložiti v kupce, ki so za podjetje veliko vredni),
- iskanje najučinkovitejših pristopov za zadovoljevanje potreb kupcev (zelo pomembno je razlikovanje kupcev glede na (i.) njihove potrebe in (ii.) njihov prispevek k podjetju),
- prilagajanje izdelkov, storitev in sporočil posameznemu kupcu (oziroma ciljni skupini kupcev),
- nagrajevanje zaposlenih za ohranjanje obstoječih kupcev,
- nagrajevanje kupcev za zvestobo ter pogovor s posameznimi kupci za gradnjo znanja o njihovih potrebah in za graditev tesnejših odnosov.

Zmagovalna podjetja so uspešnejša pri pridobivanju, zadrževanju (podaljševanju trajanja odnosa z dobičkonosnim kupcem, zmanjševanju stopnje odhajanja kupcev), razvoju (povečevanju vrednosti nakupov, pogostosti nakupov ter širine kupljenih artiklov na kupca) in razumevanju (obnašanja, potreb) kupcev. Posledično povečanje in nadgradnja odnosov s kupci trgovcu prinaša dolgoročno finančno uspešnost, znižanje stroškov na nakup/na storitev ter znižanje stroškov v povezavi z reklamacijami (Kotler 2004; Musek Lešnik 2008; Kushwaha 2014).

Trajen odnos med trgovcem in kupcem pa nima prednosti samo za trgovca, tudi kupcu prinaša pomembne ugodnosti (Marzo-Navarro in drugi 2004; Musek Lešnik 2007; Kushwaha 2014):

- prihranek v času in denarju,
- prihranek v trudu za odločanje,
- socialne ugodnosti (prijetno preživljanje časa v trgovini, pogovori s prodajalci ...),
- manjšo stopnjo tveganja (zaupanje).

Strategija osredotočenosti na kupca pa ni edina priložnost za oblikovanje konkurenčne prednosti trgovca. Omeniti velja še naslednje priložnosti: (i.) zvestoba kupcev, (ii.) lokacija trgovin, (iii.) odnos z dobavitelji, (iv.) informacijski in distribucijski sistem upravljanja, (v.) razvoj lastnih blagovnih znamk, (vi.) upravljanje s človeškimi viri, (vii.) pomoč kupcem (angl. »customer service«) ter (viii.) zmanjševanje operativnih stroškov (Levy in Weitz 2012, 115–139).

Povzetek

V času rastoče konkurence med trgovci na lokalni in globalni ravni, zaostreni cenovni tekmi ter vse bolj zahtevnimi, preudarnimi, varčnimi in informiranimi kupci, se vse bolj postavlja vprašanje kako pridobiti nove kupce, jih zadovoljiti in dolgoročno zadržati. K povečevanju zvestobe kupcev pomembno prispeva odločitev trgovca za: (i.) oblike kupcu prilagojenega trženjskega komuniciranja (konkurenčno prednost bodo imeli trgovci, ki bodo sposobni v praksi dosledno izvajati ciljano trženje podprto z znanjem o kupcih); (ii.) vlaganje v razvoj lastnih trgovskih znamk ter (iii.) za sprejetje in dosledno izvajanje strategije osredotočenosti na kupca.

Z razvojem lastnih blagovnih znamk si trgovci zagotavljajo konkurenčne prednosti, med kateri so najpomembnejše: (i.) ugled trgovca in zvestoba kupcev, (ii.) dodani prihodki in manjši stroški na enoto ter (iii.) višje marže in višji dobiček, kljub nižji ceni (Potočnik 2001).

Osredotočenosti na kupce predstavlja ključno konkurenčno prednost in je spretnost, o kateri veliko govorijo skoraj vsi trgovci. Mnogi od njih se res trudijo: marsikdo je celo prepričan, da je pri tem uspešen – nekateri imajo pri tem prav, zelo malo pa je tistih, ki pri tem polno in učinkovito izkoristijo vse potenciale, svoje in kupčeve. Zmagovalna podjetja so uspešnejša pri pridobivanju, zadrževanju, razvoju in razumevanju kupcev, kar posledično vodi v boljši poslovni rezultat.

V slovenskem prostoru prevladuje prodajni koncept trženja, kjer se kupce obravnava kot pasivne objekte. Na kupčeve nakupne odločitve poskušajo vplivati z različnimi vsiljivimi

prodajnimi metodami, manipulacijami, psihološkimi pritiski itd.⁶ Na splošno prevladuje množično trženje, kjer kupce obravnavajo kot homogeno celoto, brez upoštevanja njihovih razlik (Sfiligoj 2003). Pri večjih trgovcih se sicer kaže premik k segmentiranju ciljnih skupin kupcev skozi oglasna in druga promocijska sporočila, vendar še vedno vsi trije največji slovenski trgovci, skozi ciljano trženje ponujajo podobno (največkrat enako) ponudbo (npr. 10 % popust na vrednost nakupa – vprašanje je samo kateri dan, kateri segment, pri katerem trgovcu).

Pri razmišljanju o kupcih ne gre zgolj za načelno govorjenje o pomenu odnosov z njimi, temveč predvsem za to, kako dobro zna trgovec razumeti njihovo vedenje, navade, motive, stališča, vrednote, namene – gre za to, kako dobro jih razume⁷. Kakovost odnosa odločilno vpliva na zadovoljstvo in zvestobo kupcev. Zvestobo kupcev (v odnosu do zadovoljstva) in program zvestobe opredelim v naslednjem poglavju.

⁶ Za pregled in razumevanje različnih manipulacij trženjskih aktivnosti glej v Naghiu (Naghiu 2011) ter v Stoeckl in Luedicke (Stoeckl in Luedicke 2015), ker je podan pregled znanstvenih člankov, ki se osredotočajo na kritiko »goljufivih« trženjskih pristopov.

⁷ Kako si lahko trgovec pridobi znanje o kupcih obravnavam v četrtem poglavju.

3 ZVESTOBA KUPCEV

»Nekatera podjetja in menedžerji se pritožujejo, da je zvestoba mrtva.

Verjetno se resnice ne da zgrešiti.

Zvestoba ni mrtva ...

... je pa zanjo res treba narediti več kot včasih.«

Dr. Kristjan Musek Lešnik

Tretje poglavje je teoretični del, vezan na zvestobo kupcev. V njem opredelim pojem zvestobe kupcev, odnos med zadovoljstvom in zvestobo kupcev, pomen ohranjanja zvestobe kupcev za trgovca. Podrobneje opredelim programe zvestobe (tako vsebinski, metodološki kot etični vidik) ter poglavje zaključim z opredelitvijo oteževalnih okoliščin s katerimi se srečujejo (in se bodo v prihodnjih letih še bolj intenzivno) trgovci pri izvajanju strategije programa zvestobe (upoštevanje zakonskih predpisov na področju varovanja osebnih podatkov za potrebe: obdelave osebnih podatkov, segmentiranja, za potrebe ciljanega trženja, za spoštovanje kupčevih pravic ...).

3.1 Opredelitev zvestobe

Zvestoba⁸ kupcev je največja priložnost za oblikovanje konkurenčne prednosti trgovca (Bagdonienė in Jakštaitė 2007; Levy in Weitz 2012; Ho in drugi 2015). V današnjem svetu (kjer je konkurenca vedno bolj agresivna⁹ in vedno bolj spretna v »tekmi« za kupce) je zvestoba kupcev zelo pomembna, verjetno bolj pomembna kot kadarkoli prej. Dobra novica je, da lahko trgovci na zadovoljstvo kupcev neposredno vplivajo z načrtnimi, sistematičnimi ter doslednimi strategijami, s katerimi zadovoljstvo spodbujajo, gradijo, vzdržujejo ter pospešujejo. Slaba novica je, da jo z neetičnimi in ciničnimi ravnanji hitro izgubijo (Musek Lešnik 2008; Nguyen in Klaus 2013; Stoeckl in Luedicke 2015).

⁸ Zvestoba je nasploh definirana kot ena od človekovih čustev in pomeni pripadnost neki ideji, človeku ali tudi predmetu (Damjan in Možina 1998, 144). V pričujočem magistrskem delu se omejujem na zvestobo trgovcu.

⁹ V takšni situaciji se po Pattersonu (povzeto po Musek Lešnik 2008, 13) nujno zgodita dve reči: zaostri se cenovna tekma in upade zvestoba kupcev.

Pri merjenju in opredelitvi zvestobe so si, predvsem zaradi kompleksnosti in večpomenskosti, neenotni tudi akademski raziskovalci (Snoj in Gabrijan 2015, 91). Pri merjenju zvestobe in definiranju segmenta najbolj zvestih kupcev so najpogosteje uporabljena naslednja merila (Griffin 2002; Sällberg 2010; Naghiu 2011; Martoz-Partal in González-Benito 2013; Pleshko in Heiens 2015; Radder in drugi 2015; Snoj in Gabrijan 2015; do Vale in drugi 2016):

- pogostost ponovnih nakupov (ponakup ni dogodek slučaja),
- velikost nakupov (vrednost nakupov),
- namera ponovnega nakupa,
- nakupi znotraj različnih blagovnih skupin (širina kupljenega asortimenta),
- namera kupovanja večje količine/vrednosti/širine (povečanje deleža nakupov kupca pri trgovcu – angl. »*share-of-wallet*«/»*retailer`s share of customer*«),
- namera dajanja priporočil (deljenje pozitivne izkušnje z drugimi) in izražanja razlogov za nezadovoljstvo,
- pozitivna priporočila od ust do ust,
- verjetnost zamenjave podjetja (trgovca) ali (trgovske) blagovne znamke.

Pomen zvestobe kupcev za trgovca nakazujejo njene posledice: (i.) prihranek (strošek zadrževanja zvestega kupca je nekajkrat manjši kot strošek pridobivanja novega kupca), (ii.) povečanje prihodkov (zvesti kupci kupujejo večkrat v večji prodajni vrednosti, so manj občutljivi na cene, so pripravljene plačati tudi več kot pri konkurenci ...), (iii.) priporočila in prisotnost v zavesti kupcev (zvesti kupci delijo pozitivne izkušnje z znanci, trgovec je pogosteje v njihovi zavesti kot pri povprečnem kupcu), (iv.) ohranjanje baze obstoječih kupcev (zvesti kupci so manj dojemljivi za ponudbe konkurence) ter (v.) pozitiven in aktiven odnos z najbolj zvestimi kupci (zvesti kupci se bolj zavedajo dodatnih možnosti, ki jih ponuja odnos s trgovcem; bolj so naklonjeni novim izdelkom ali storitvam ali novim prodajnim kanalom; trgovcu hitreje oprostijo napake – v primeru negativnih izkušenj se pogosteje obrnejo na trgovca, preden se odločijo za odhod drugam; pozitivni občutki kupca do trgovca ter želja po ohranjanju odnosov ...).

Za trgovca je zelo pomembno da prepozna »lažno zveste« kupce, za katere velja, da je ponovljivost nakupov posledica pomanjkanja alternativ (posledica zunanjih dejavnikov), ne pa pozitivnih stališč (Musek Lešnik 2008; Radder in drugi 2015). Zelo pogosto trgovci zveste kupce nagovarjajo enako kot »lažno zveste« kupce ali celo enako kot vse druge kupce. Ni pa to edina napaka povezana s podcenjevanjem zvestobe, samozadovoljstvo trgovca (prepričanje,

da je zadovoljstvo samoumevno; občutek trgovca, da vse počne prav), nepoznavanje vzrokov za zadovoljstvo, nerazumevanje zvestih kupcev ... – posledica teh napak je upad zvestih kupcev ali celo propad programa zvestobe (Bagdonienė in Jakštaitė 2007; Musek Lešnik 2008; Nguyen in Klaus 2013; Steinhoff in Palmatier 2016).

Zvestoba kupcev je torej več kot le vračanje in ponavljanje nakupov – je pojem, ki ga je moč razumeti in uporabiti (tudi zlorabiti) na več načinov. Tudi nerazumevanje odnosa med zadovoljstvom in zvestobo (več v naslednjem podpoglavju) ima za trgovca negativne posledice.

3.2 Odnos med zadovoljstvom in zvestobo

»Zadovoljstvo kupca je psihološko stanje, ki izhaja iz procesa nakupnega odločanja in se dokončno oblikuje v ponakupni fazi« (Možina in drugi 2012, 187). Zadovoljstvo lahko torej opredelim kot čustveni odgovor na doživeto izkušnjo pri trgovcu, opravljeni nakup, prejeto storitev. Zelo pomemben dejavnik zadovoljstva s posamezno izkušnjo so vnaprejšnja kupčeva pričakovanja: občutek zadovoljstva ali nezadovoljstva se razvije na podlagi primerjave med pričakovanji in doživeto izkušnjo oziroma zaznane kakovosti aktualnega izdelka ali storitve (Musek Lešnik 2008, Naghiu 2011; Možina in drugi 2012; Hunt v Pleshko in Heiens 2015, 56–57).

Zadovoljstvo kupcev je pomemben dejavnik njihove zvestobe, ni pa edini zadostni pogoj. Zadovoljen kupec, še ni zvest kupec (Renko in Družijanić 2014¹⁰; Pleshko in Heiens 2015). Zgolj zadovoljstvo namreč še ni zagotovilo, da se bo kupec vračal. Med zadovoljstvom in zvestobo ni linearne povezave (Musek Lešnik 2008, Možina in drugi 2012; Pleshko in Heiens 2015), kar nakazujejo naslednja dejstva:

- nezadovoljstvo kupca je zadosten razlog za »prebeg« drugam, vendar zadovoljstvo ni zadosten razlog za razvijanje pozitivnih stališč, ponakup, nadaljnjo dolgoročno vračanje in zvestobo;
- vsi nezadovoljni kupci ne odidejo h konkurenci ter

¹⁰ V članku avtorja dokazujeta, da uporaba novih inovativnih tehnologij v trgovinah pomembno vpliva na zadovoljstvo kupcev, ne zagotavlja pa zvestobe kupcev.

- vsi zadovoljni kupci ne ostanejo zvesti (tudi zadovoljni kupci lahko nenadoma odidejo drugam).

Je pa zadovoljstvo dejavnik na katerega lahko trgovec neposredno vpliva. Če si želi trgovec pridobiti zadovoljne in zveste kupce, mora kupcu ponuditi nekaj več od konkurence, mora znati prisluhnuti svojim kupcem in jim odgovoriti s ponudbo, ki učinkovito nagovori in čim boljše zadovolji njihove želje in potrebe. Tukaj so pa trgovcem v veliko pomoč programi zvestobe, ki jih opredelim v naslednjem podpoglavju.

3.3 Program zvestobe

»Kartica zvestobe ne prinaša zvestobe ...

Omogoča, da spoznaš kupca.

Je pristop, s katerim iščeš in uporabiš znanje za pridobitev zvestobe.«

SAS Institute d.o.o.

Programi zvestobe (uporabljajo se tudi izrazi: klub zvestobe, klub potrošnikov, kartica zvestih nakupov, kartica zvestobe, kartica zaupanja, kartica ugodnosti ...) so eden od najbolj razširjenih orodij upravljanja odnosov s kupci (Sharp in Sharp 1997; Kumar 2006; Bagdonienė in Jakštaitė 2007; Liu 2007; Musek Lešnik 2008; Ograjenšek in Žabkar 2010; Sällberg 2010; Steinhoff in Palmatier 2016). Programi zvestobe so različno zasnovani, vendar imajo vsi skupne točke:

- pritegniti kupca in zadovoljiti njegovo potrebo po ponovnem nakupu,
- povečati pogostost nakupov na kupca,
- povečati vrednost nakupov na kupca.

Zamisel o oblikovanju programov za povečevanje zvestobe kupcev¹¹ (z vzpodbujanjem k rednemu in pogostejšemu nakupu) se je najprej porodila velikim letalskim družbam (*American Airlines* leta 1981 s programom zvestobe *AAdvantage*; *Adria Airways*¹² leta 1990 s programom zvestobe *Adria Privilege Club*), danes pa so prisotni že v večini panog:

¹¹ Gregorčič (2004, 35) program za povečevanje zvestobe kupcev opredeli kot strateški in operativni načrt izvajanja vseh projektov in drugih dejavnosti z namenom krepitev vezi in odnosov s kupci, kar naj privede do končnega cilja – ohranjanja in večanja zvestobe kupcev.

¹² Danes ima *Adria Airways* dva programa zvestobe: (i.) »*Miles & More*« za individualna potovanja in (ii.) »*Adria Corporate Card*« za podjetja (*Adria*).

gostinstvo, hotelirstvo, trgovina na drobno, bančništvo, zavarovalništvo, mobilna telefonija, telekomunikacije ... (Ograjenšek 2002a; Ograjenšek 2002b; Wulf in drugi 2003; Liu 2007; Steinhoff in Palmatier 2016). Članstvo v programu zvestobe je v veliki večini brezplačno (npr. v Sloveniji pri vseh treh največjih trgovcih), lahko pa je tudi plačljivo (npr. v Sloveniji program zvestobe »Klub 5*« trgovca Studio Moderna d.o.o.). Širšo obravnavo vpliva plačljivosti na uspešnost programa zvestobe obravnava članek »*The effect of loyalty program fees on program perceptions and engagement*«, pod avtorstvom Christy Ashley, Erin A. Gillespie in Stephanie M. Noble (Ashley in drugi 2016).

Zelo splošno rečeno, je program zvestobe trženjska aktivnost, ki ponuja kupcem nagrade, vezane na pogostnost in obseg nakupov izdelkov/storitev določenega podjetja (Kotler 2004, 612; Kumar 2006, 163). Tradicionalno so bili programi zvestobe zasnovani kot trženjsko orodje za preprečevanje prebega kupcev h konkurenčnim podjetjem, vendar jih danes že večina presega to vlogo, v ospredje prihaja vloga, ki jo igrajo v procesih zbiranja in obdelave podatkov kupcev (članov programov zvestobe) s poudarkom na odkrivanju vzorcev nakupnega obnašanja (Ograjenšek 2002a; Ograjenšek 2005; Liu 2007; Jentzsch in drugi 2013; Renko in Družijanić 2014; Meyer-Waarden 2015; Jai in King 2016).

Vloga in pomen programa zvestobe v poslovnem okolju trgovca presega tradicionalne trženjske pristope do kupcev, ki se osredotočajo zgolj na obrambno (defenzivno) ali napadalno (ofenzivno) poslovno strategijo¹³, programi zvestobe pa poskušajo kombinirati oba pristopa (Ograjenšek 2005; Musek Lešnik 2008). Čeprav se večina (manjših) trgovcev osredotoča zgolj na obrambno strategijo – ohranjanju obstoječih kupcev s strategijami usmerjenimi k razvijanju in poglobljanju odnosov s kupci, spodbujanju njihovega vračanja in višanju njihove zvestobe, ne gre zanemariti vloge zbranih podatkov pri razvoju napadalne poslovne strategije, za pridobivanje novih kupcev oziroma za širjenje baze kupcev (Ograjenšek 2005; Ograjenšek in Žabkar 2010; Ho in drugi 2015).

Programi zvestobe so torej orodja, ki učinkovito integrirajo **vsebinske** (se nanašajo na vlogo programa zvestobe kot pospeševalca zvestobe oziroma preprečevalca prebega h konkurenci), **metodološke** (se nanašajo na vlogo programa zvestobe v procesu spoznavanja in usmerjanja

¹³ Fornellova (povzeto po Ograjenšek 2002a) razvrstitev poslovnih strategij na obrambne (defenzivne) in napadalne (ofenzivne) predstavlja učinkovit analitični okvir za ugotavljanje vloge in pomena programov zvestobe v poslovnem procesu.

kupcev – poleg zbiranja in analize podatkov zajema tudi oblikovanje ustrezne poslovne strategije trgovca) in **etične** (se nanašajo na preglednost varstva in obdelave osebnih podatkov kupcev, na spoštovanje pravic kupcev, poštenost nagrad ...) **elemente**¹⁴ programa zvestobe, v enovit in celovit pristop, usmerjen k vzpostavljanju, razvijanju in vzdrževanju odnosov s kupci in k spodbujanju njihove zvestobe (Ograjenšek 2002a; Ograjenšek 2002b).

V poplavi programov zvestobe je potrebno ločiti med »pravimi« in »nepravimi« programi zvestobe. Pri nepravih programih zvestobe gre za zelo velik razkorak med obstoječim stanjem in strategijo programa zvestobe. Prav tako se nepravi programi zvestobe preveč osredotočajo na ponavljanje nakupov, ponujanje predvsem denarnih ugodnosti (popustov), premalo pa gradijo na zaupanju.

Zelo pomembno je, da se trgovec zaveda problema kakovosti podatkov (npr. osnovni demografski in socio-ekonomski podatki so običajno v bazo vneseni samo enkrat in se ne posodablajo) in pristranskosti podatkov (značilnosti članov programa zvestobe se lahko pomembno razlikujejo od značilnosti nečlanov), zbranih v okviru programa zvestobe (Ograjenšek 2002a), kakor tudi CRM sistema (Abbott in drugi 2001; Reid in Catterall 2005; Ofner in drugi 2012).

Vse bolj oteževalna okoliščina za programe zvestobe postaja naraščajoči strah kupcev pred zlorabo podatkov (Sällberg 2010; Jai in drugi 2013; Nguyen in Klaus 2013; Stoeckl in Luedicke 2015; Jai in King 2016) ter posledično vse obširnejše vladne aktivnosti (na državnem in evropskem nivoju) na področju varstva osebnih podatkov. Prav tako so kupci vse bolj obveščeni o svojih pravicah v vlogi kupca ter Zveza potrošnikov Slovenije (ZPS¹⁵) in Urad za varstvo potrošnikov¹⁶ postajata vse »glasnejša« in prepoznavna. Podrobneje o tem področju v naslednjih dveh podpoglavjih.

¹⁴ Več o vsebinskih, metodoloških in etičnih elementih programa zvestobe glej v Ograjenšek (2002a; 2002b).

¹⁵ ZPS je neodvisna, neprofitna, mednarodno priznana nevladna organizacija, ki že od leta 1990 varuje in zastopa izključno interese potrošnikov: informirajo, svetujejo, testirajo izdelke, izobražujejo, zastopajo interese potrošnikov, delujejo mednarodno (Zveza potrošnikov Slovenije).

¹⁶ Urad za varstvo potrošnikov v Sloveniji deluje kot samostojni organ šele od leta 1996, na področju EU so se takšni organi vzpostavili že v šestdesetih in sedemdesetih letih prejšnjega stoletja (Urad za varstvo potrošnikov). Za kupce je predvsem pomembna modra številka 080 88 99, preko katere nudijo brezplačno svetovanje.

3.3.1 Varstvo osebnih podatkov v kontekstu programa zvestobe

V Sloveniji pravno podlago za obdelavo osebnih podatkov določa Zakon o varstvu osebnih podatkov (ZVOP-1-UPB1, v nadaljevanju ZVOP-1). Splošna pravna podlaga za obdelavo osebnih podatkov je določena v 8. členu ZVOP-1, konkretno za zasebni sektor (kamor spadajo tudi trgovci) v 10. členu ZVOP-1 ter za pogoje izvajanja neposrednega trženja v 72. členu ZVOP-1. Osebni podatki¹⁷ se lahko obdelujejo le, če obdelavo osebnih podatkov¹⁸ določa zakon ali če je za obdelavo osebnih podatkov podana osebna privolitev posameznika.

Privolitev posameznika (pri čemer mora biti posameznik predhodno ustrezno seznanjen z namenom obdelave osebnih podatkov) je torej edina pravna podlaga za obdelavo osebnih podatkov v primeru članov programa zvestobe. Trгоvec se lahko svobodno odloča o tem, katere zasebne podatke bo zahteval od posameznika kot pogoj za sklenitev določenega pravnega posla (članstvo v programu zvestobe) z njim, obdelati se pa smejo le tisti osebni podatki, ki so primerni in nujno potrebni za uresničitev opredeljenega namena (16. člen) in ne pomenijo neupravičenega posega v zasebnost in dostojanstvo posameznika. Prav tako trgovec sam določa pogoje poslovanja (članstva) za imetnike kartice zvestobe oziroma člane programa zvestobe, vendar pri tem ne sme zaobiti temeljnih načel obdelave osebnih podatkov: poštenosti, zakonitosti in sorazmernosti (Informacijski pooblaščenec 2004).

Načelo poštenosti zahteva, da se namen obdelave osebnih podatkov ne sme navesti nejasno, ali tako, da ga je mogoče preširoko razlagati oziroma na način, da se posameznika zavede. Zakonsko potrebne informacije po 19. členu ZVOP-1 (podatek o upravljavcu osebnih podatkov; namen obdelave osebnih podatkov; informacije o pravici do vpogleda, prepisa, kopiranja, dopolnitve, popravka, blokiranja in izbrisa osebnih podatkov) morajo biti predstavljene (oziroma napisane) enostavno, nedvoumno in v primerni velikosti tiska – ni pošteno, kadar trgovec (kot upravljavec osebnih podatkov) te informacije navede le v sklopu svojih splošnih pogojev.

¹⁷ Osebni podatek je kateri koli podatek, ki se nanaša na posameznika, ne glede na obliko v kateri je izražen (ZVOP-1-UPB1, 6. čl.).

¹⁸ Obdelava osebnih podatkov – pomeni kakršno koli delovanje ali niz delovanj, ki se izvaja v zvezi z osebnimi podatki, ki so avtomatizirano obdelani ali ki so pri ročni obdelavi del zbirke osebnih podatkov ali so namenjeni vključitvi v zbirko osebnih podatkov (ZVOP-1-UPB1, 6. čl.).

Za potrebe neposrednega (ciljanega) trženja se lahko uporabijo le kontaktni podatki (ime, priimek, naslov, telefonska številka, naslov elektronske pošte (72. člen). Ostali pridobljeni podatki se lahko uporabijo zgolj na podlagi izrecne in praviloma pisne privolitve posameznika. Člani programa zvestobe torej morajo imeti v primeru ciljanega trženja možnost izrecno soglašati v tako obdelavo osebnih podatkov. Informacijski pooblaščenec (2004) meni, da bi morali trgovci (upravljalci osebnih podatkov), ki pridobivajo osebne podatke (iz programa zvestobe in iz nakupov) in le-te nadalje obdelujejo (za potrebe segmentiranja in izvajanja ciljanega trženja) na pošten način, člane programa zvestobe o ciljanem trženju, kot specifičnem namenu obdelave osebnih podatkov, obveščati izrecno. Kar pomeni, da bi morali privolitve v obdelavo osebnih podatkov za ta namen pridobivati ločeno.

Tudi Evropska unija se vse bolj intenzivno osredotoča na področje varovanja osebnih podatkov – z intenzivnimi ukrepi za prenovo in dopolnitev direktive o varstvu podatkov iz leta 1995 (CMS International 2014). Tako je Evropska komisija leta 2012 (25. januarja 2012) sprejela predlog reforme (Splošna uredba o varstvu podatkov), o katerem so potekala nadaljnja štiri leta zelo intenzivna usklajevanja in pogajanja. Konec leta 2015 (15. decembra 2015) sta Evropski parlament in Evropski Svet dosegla dogovor o zakonodajnem svežnju, ki ga sestavljata Splošna uredba o varstvu podatkov in Predlog direktive o varstvu posameznikov pri obdelavi osebnih podatkov. Dogovor bo formalno potrjen predvidoma spomladi 2016, ko bo Evropski parlament glasoval na plenarnem zasedanju in bo Evropski Svet potrdil besedilo. Uredba bo začela veljati takoj v vseh državah članicah, brez da bi morali nacionalni organi zato sprejeti kakšen zakonodajni ukrep – njene določbe bodo prevladale (z načelom primarnosti prava Evropske Unije) nad lokalnimi določbami o varstvu podatkov (European Commission 2015, 15. december; Ministrstvo za pravosodje 2015, 21. december; Robinson 2015; Scott 2015).

Po pričakovanjih naj bi zakon prišel v veljavo najkasneje v roku dveh let, zato je izjemno pomembno, da se trgovci na bodoče spremembe (širša definicija osebnega podatka, strožja definicija posameznikove privolitve – dokazno breme v zvezi z obstojem soglasja bo imelo podjetje, dolžnost obveščanja uporabnika o obdelavi njegovih osebnih podatkov – način obdelave, prenašanja, zavarovanja, shranjevanja, posredovanja podatkov) pravočasno pripravijo. V primeru kršitev, bo imel Informacijski pooblaščenec pristojnost izreči kar 8000 krat višjo globo (kazen v višini do 100 milijonov EUR oziroma do 5 % letnega svetovnega prometa), kot je to sedaj.

3.3.2 Pravice kupcev

Trgovci pogosto poskušajo v medsebojnem konkurenčnem boju kupe pritegniti v svoje trgovine na različne nepoštene načine (Potočnik 2001, Snoj in Gabrijan 2015) oziroma se ne ravnaajo v skladu z dobrimi poslovnimi običaji: dajanje napačnih informacij; prevara glede cene, kakovosti ali funkcionalnosti izdelka; prikrito oglaševanje; lažno obljubljanje nagrad, vztrajno in nezaželeno nagovarjanje po telefonu ...¹⁹

Da bi se povečalo zaupanje kupcev (širše potrošnikov) je bila v Sloveniji sprejeta Resolucija o nacionalnem programu varstva potrošnikov (ReNPVP), ki obsega osem temeljnih pravic²⁰:

- (1) pravica do osnovnih dobrin in storitev – brez katerih ni možno dostojno preživetje (npr. voda, hrana, zdravila ...);
- (2) pravica do varnih proizvodov in storitev na trgu – ki ne predstavljajo tveganja za zdravje in varnost potrošnikov;
- (3) pravica do obveščенosti (pravica do razumljivih in nepristranskih informacij);
- (4) pravica do izbire – na trgu blaga in storitev, ki potrošniku omogoča svobodno odločanje na trgu;
- (5) pravica do zastopanosti – do organiziranja v interesne skupine, ki zastopajo interese potrošnikov;
- (6) pravica do pravnega varstva;
- (7) pravica do izobraževanja (ne glede na starost in spol);
- (8) pravica do zdravega in trajnostno naravnega okolja (ta pravica potrošnikom nalaga tudi dolžnosti – etično nakupne odločitve).

Vendar zagotavljanje pravic kupcev zgolj na zakonodajni ravni ni dovolj, potrebno je zagotoviti, da lahko kupci svoje pravice uveljavljajo tudi v praksi. Tukaj nastopi vloga Tržnega inšpektorata (Tržni inšpektorat Republike Slovenije), ki je poleg redne sodne poti (reševanje potrošniških sporov in inšpekcijski nadzor na področju varstva potrošnikov²¹)

¹⁹ Za takšne prakse, ki temeljijo na sistematičnem zavajanju se v literaturi uporablja izraz »gonzo marketing« (Snoj in Gabrijan 2015).

²⁰ Že leta 1986 je Organizacija združenih narodov sprejela Smernice varstva potrošnikov, ki so bile leta 1999 dopolnjene, tako da danes obsegajo osem pravic, ki predstavljajo temeljna načela politike varstva potrošnikov (ReNPVP, 1.3 čl.).

²¹ »Potrošnik« je fizična oseba, ki pridobiva ali uporablja blago in storitve za namene, ki niso povezani z njeno poklicno ali pridobitno dejavnostjo (ZVPNPP: Uradni list RS, št. 53/07).

vzpostavil ustrezen sistem, kjer lahko kupec hitro, brez ali z relativno majhnimi stroški (npr. stroški sodnega izvedenca) doseže rešitev spora s trgovcem.

Glavni razlogi (v primeru trgovcev) za neučinkovito varstvo kupcev so po Potočniku (2001, 73–74) najpogosteje naslednji:

- kupci ne poznajo zakonskih pravic glede reklamacij in varstva svojih pravic;
- kupci so v podrejenem položaju, saj ne poznajo značilnosti izdelkov;
- kupci praviloma ne zahtevajo zaščite pri inšpekcijskih organih;
- v večini primerov trajajo sodni spori dolgo časa.

Kupci se moramo zavedati svojih pravic in jih tudi uveljavljati, saj s tem največ pripomoremo k zmanjševanju nepoštenih praks trgovcev.

Povzetek

Trgovec mora za načrtno ustvarjanje, zadrževanje in povečevanje zvestobe kupcev:

- Opredeliti **kdo je zvesti kupec**: natančno definirati pogoje oziroma kriterije za zvestobo; za vsakega kupca v bazi mora imeti podatek o zvestobi (zvest: da/ne). Najpogostejši način za merjenje zvestobe kupcev je RFM segmentacija kupcev (**R**: število dni od zadnjega nakupa; **F**: število nakupov; **M**: bruto dobiček ali prodajna vrednost; angl. »*recency frequency value segmentation*«), kjer je eden izmed segmentov »top zvesti kupci« (npr. segmenti: »diamantni kupci«, »zlata kupci«, »srebrni kupci«, »bronasti kupci«). Segmentacija ima naslednje lastnosti: vsi segmenti so izvedljivi, merljivi, stabilni in enostavno opisljivi; nizek strošek za izgradnjo segmentacije; dokazan povratek investicije (McCarty 2007; Stafford 2009; Dash in Suryakanta 2010).
- Opredeliti **kako meriti zvestobo**: koliko zvestih kupcev izgubijo, koliko pridobijo in koliko zadržijo (mesečno, kvartarno, letno). V primeru segmentacije lahko to merijo s spremljanjem prehajanja kupcev med segmenti (npr. koliko jih je padlo iz segmenta »diamantni kupci« v segment »zlata kupci«).
- Dosledno **izvajati strategijo programa zvestobe**, skozi katerega članu ponudi nekaj več, t.i. dodano vrednost.

- **Zavedati se mora bogastva svoje baze podatkov**, ki je osnova za pravi program zvestobe, za graditev odnosa s kupci in za aktivnosti ciljanega trženja.

Površnosti, ki jih zgrešijo trgovci pri strateškem upravljanju z zvestobo kupcev, so največkrat posledica površnega razumevanja kupcev. Tukaj jim je lahko v veliko pomoč podatkovno rudarjenje, ki je podrobneje opredeljeno v naslednjem poglavju.

4 PODATKOVNO RUDARJENJE

»Človek in računalnik sta sposobna doseči, česar nobeden od njiju sam ne zmore.«

Hubert L. Dreyfus

V tem poglavju opredelim pojme, ki so zelo tesno povezani s podatkovnim rudarjenjem: proces odkrivanja znanja v podatkih (angl. »*knowledge discovery in databases*«), podatkovno rudarjenje (angl. »*data mining*«), večrelacijsko ali induktivno logično programiranje (angl. »*inductive logic programming*«), strojno učenje (angl. »*machine learning*«), vizualizacija (angl. »*visualization*«), CRISP-DM metodologija (angl. »*cross-industry standard process for data mining*«).

Opredelim področje uporabe podatkovnega rudarjenja – kakšne probleme rešuje, kakšni so cilji podatkovnega rudarjenja ter kakšne tehnike podatkovnega rudarjenja so mi na voljo za reševanje specifičnega problema. Vse skupaj povežem s primeri iz ciljanega trženja ter na koncu poglavja podam pregled prednosti in omejitev uporabe orodja za podatkovno rudarjenje v podjetjih (s poudarkom na trgovski dejavnosti). Poglavje zaključim s pregledom nekaterih raziskav na tem področju v slovenskem okolju.

4.1 Podatki in znanje (v kontekstu virov za podatkovno rudarjenje)

Količina podatkov, ki je na razpolago danes, sama ne dovoljuje, da bi ljudje izvajali analize in tako še vedno ostaja ogromna količina neobdelanih podatkov – neanaliziranih dejstev, ki so shranjena v podatkovni bazi trgovca (Brumen 2004).

Neanalizirani podatki (shranjeni v podatkovni bazi) ter podatki, ki so sami po sebi gola dejstva, ne pripomorejo h konkurenčni prednosti trgovca (ali kakršnega koli podjetja). Prav nasprotno, povzročajo dodatne stroške (stroške shranjevanja, vzdrževanja, varovanja) in so popolnoma neuporabni pri sprejemanju poslovnih odločitev. Podatke je torej potrebno analizirati in jih pretvoriti v uporabne informacije (Brumen 2004; Seng in Chen 2010) in jih uporabiti za razvoj in izvajanje učinkovitejših, prilagojenih in personaliziranih trženjskih aktivnosti (Dumitru in drugi 2015, 521) – podatki o kupcih še nikoli niso bili tako pomembni kot so danes (Jai in King 2016; 296). Trgovci se tako soočajo z odvisnostjo/neskladjem med

znanjem/podatki, ki so na voljo in nezmožnostjo uporabe le-teh. Ključno vprašanje torej je, kako iz zbranih podatkov izluščiti znanje.

Kako oziroma katero tehniko izbrati je odvisno tudi od podatkov, ki jih imamo na voljo. Na grobo podatke delimo na (Brumen 2004):

- **strukturirane podatke**, ki imajo strukturo zelo dobro definirano (podatki v podatkovnih bazah, ki vsebujejo tabele in relacije),
- **nestrukturirane podatke**, ki imajo malo strukture ali je sploh nimajo (predvsem tekstovni zapisi, npr. članki, poročila, spletne strani ...) ter
- **časovno odvisne podatke**, kjer podatki vsebujejo čas kot pomemben parameter.

Podatki, zbrani v okviru programa zvestobe, so strukturirani podatki in jih lahko razdelimo v tri skupine (Ograjenšek in Žabkar 2010, 135):

- **transakcijski podatki** (podatki na računu: čas nakupa, kraj nakupa, kupljeni izdelki, cena izdelkov ...),
- **demografski in socioekonomski podatki** (podatki o kupcih: spol, starost, kraj bivanja, izobrazba ...) ter
- **anketni podatki** (podatki iz raziskav zadovoljstva ...).

Podatki so shranjeni v relacijski podatkovni bazi, v kateri je več tabel, ki so med seboj povezane z relacijami. V primeru programa zvestobe gre torej za učenje iz več relacijskih tabel (tabela artiklov, tabela poslovnih enot, tabela nakupov, tabela kupcev ...), t.i. večrelacijsko učenje ali induktivno logično programiranje (na kratko ILP). V empiričnem delu magistrske naloge ne bom uporabila metod ILP-ja (logični programski jezik Prolog), temveč bom v koraku priprave podatkov, iz večrelacijskih tabel pripravila eno tabelo v strukturi primerni za izbrano tehniko podatkovnega rudarjenja.

V magistrskem delu vsako vrstico v tabeli imenujem objekt (angl. »*object*«; v tabeli demografskih podatkov je objekt posamezen kupec oziroma član programa zvestobe Tuš kluba; v tabeli transakcijskih podatkov je objekt artikel na poziciji), stolpec pa atribut (angl. »*attribute*« – predstavljajo lastnosti opazovanih objektov; npr. pri preučevanju kupcev me zanimajo naslednje lastnosti: spol, starost, število nakupov ...). V statistiki se za objekt uporablja izraz enota, za atribut pa izraz spremenljivka. Izbira atributov in njihovo razumevanje (s statističnega in poslovnega vidika) je odločilnega pomena pri izbiri tehnike

podatkovnega rudarjenja. Attribute v osnovi delimo na (Ferligoj 1989; Pyle 1999; Košmelj 2001):

- **neodvisne**, na osnovi katerih: zgradimo model, pojasnujemo odkrite vzorce v podatkih ... (npr. demografski podatki) in
- **odvisne**, ki so lahko: odločitev (npr. zvesti kupec: da/ne), grupa oziroma razred (npr. bronasti kupci), verjetnost razreda pri danih vrednostih atributov (npr. 0,75) ...

Dodatno jih delimo glede na mersko lestvico na:

- **Opisne**: vrednosti atributov lahko le opišemo z besedami (npr. narodnost) in jih nadalje delimo na:
 - nominalne: objekte lahko le primerjamo med seboj, npr. regija (poseben primer nominalnega atributa je binarni atribut, ki ima le dve vrednosti: »ima določeno lastnost«/»nima te lastnosti«, npr. da/ne, 0/1, bolan/zdrav ...) ter
 - ordinalne: objekte lahko tudi uredimo med seboj, npr. izobrazba.
- **Številске**: vrednosti atributov so realna števila (npr. skupna potrošnja v določeni trgovini v obdobju enega meseca) in jih nadalje delimo na:
 - intervalne: dopušča primerjati le razlike med dvema vrednostima (npr. temperatura zraka) ter
 - razmernostne: dopušča primerjati količnike med dvema vrednostima (npr. velikost naselja).

Opredeliti je potrebno še pojem »znanje«, saj se v magistrskem delu zelo pogosto pojavlja. V literaturi je možno zaslediti več definicij kaj znanje je, vendar za potrebe magistrskega dela zadostuje, da termin opredelim zelo na splošno: vzorci, povezave in zakonitosti, ki jih zasledimo v podatkih, nadaljnja analiza in ocenitev vzorcev ter inteligentno reagiranje (interpretacija in predstavitev znanja) na osnovi pridobljenih vzorcev (Brumen 2004; Lavrač 2007/08). Krajše lahko znanje opredelim kot interpretacijo informacije, ki jo nosijo podatki, torej vsak podatek je ob definirani interpretaciji znanje (Kononenko 2005, 36).

Odkrivanje znanja je širok pojem, v literaturi najdemo različne postopke in pristope pri iskanju znanja. V nadaljevanju opredelim postopek odkrivanja znanja v podatkih, krajše KDD (angl. »*knowledge discovery in databases*«), strojno učenje ter podrobno opišem proces (na osnovi CRISP-DM metodologije), cilje, naloge in tehnike podatkovnega rudarjenja.

4.2 Opredelitev odkrivanja znanja v podatkih, podatkovnega rudarjenja in strojnega učenja

Po Fayyadu (Fayyad in drugi 1996b, 30) je »**odkrivanje znanja v podatkih**« proces identifikacije veljavnih, novih, potencialno uporabnih in razumljivih vzorcev v podatkih.« Pri čemer: proces opredeli kot interaktivni proces čiščenja podatkov in luščenja koristnih informacij/znanja iz podatkov; veljavnost omogoča posplošitve tudi za prihodnost; novi vzorci v podatkih so doslej še neznane relacije v podatkih; uporabnost vzorcev v podatkih opredeli kot koristnost za reševanje zastavljene naloge ter razumljivost vzorcev omogoča človeško razumevanje in nova znanja.

Odrivanje znanja v podatkih je torej v najširšem smislu odkrivanje uporabnega (ter novega) znanja iz podatkov, pri čemer je »**podatkovno rudarjenje**« ključen korak znotraj tega procesa – uporaba specifičnih algoritmov za identificiranje zanimivih vzorcev (modelov) znotraj podatkov (Fayyad in drugi 1996b, 28). Opredelitev podatkovnega rudarjenja kot proces odrivanja informacij in zanimivih vzorcev v podatkih (s poudarkom na uporabnosti pridobljenega znanja v praksi) je v literaturi pogosto prisotno (Berson in Smith 1997; Pyle 1999; Podgorelec 2001; Witten in Frank 2005).

Strojno učenje izhaja iz področja umetne inteligence. Izhaja iz prizadevanja, da bi vidike biološkega učenja (človek, žival) prenesli na modele, računalniške sisteme, ki se znajo prilagajati in učiti iz izkušenj primera (Lavrač 2007). Osnovni princip strojnega učenja je torej avtomatsko opisovanje pojavov iz podatkov (Kononenko 2005). Takšen sistem je uporaben v mnogih primerih, posebej kadar lahko dobro opišemo same podatke, ne moremo pa sami odkriti pomembne povezave med njimi (zaradi prevelike količine podatkov, kadar je ročna tvorba programov zelo zahtevna, kadar nimamo dovolj znanja, kadar se poslovne zahteve nenehno spreminjajo ...). Za razkritje teh povezav se pogosto uporabijo metode strojnega učenja, ki so pogosto uporabljene med tehnikami podatkovnega rudarjenja.

Vse tehnike delimo na nadzorovano učenje (angl. »*supervised learning*«) in nenadzorovano učenje (angl. »*unsupervised learning*«). Pri nadzorovanem učenju imamo podatek o pripadnosti objekta k skupini²² (rezultat ovrednotimo tako, da ga primerjamo z realnimi

²² Odvisni atribut je lahko nominalni, ordinalni ali številski.

podatki), medtem ko pri nenadzorovanem učenju tega podatka nimamo (pravilnost rezultata je predmet interpretacije in sposobnost razumevanja). Izjema je le odkrivanje podskupin (kombinacija obeh) – kjer je glavna naloga odkrivanje posameznih pravil, ki opisujejo zanimive zakonitosti v podatkih iz klasificiranih primerov (Kononenko 2005).

Podatkovno rudarjenje ima tako osnovo oziroma se prepleta s področji: podatkovnih baz, umetne inteligence, strojnega učenja, statistike, vizualizacije, prepoznavanja vzorcev, mehkega računanja (tehnik za klasifikacijo in zajemanje znanja v podatkih), obravnave besedil (analiza spletnih strani; kategorizacija besedil: zajemanje, filtriranje in strukturiranje informacij; procesiranje naravnega jezika ...) in z drugimi področji (Fayyad in drugi 1996; Fayyad in drugi 1996a; Fayyad in drugi 1996b; Weiss in Indurkha 1998; Fayyad in drugi 2002; Brumen 2004; Lavrač 2007/08).


Če povzamem, je odkrivanje znanja v podatkih proces gradnje modelov in identifikacije zanimivih ter novih vzorcev v podatkih. Sam proces vključuje tri faze:

- razumevanje in priprava podatkov (razumevanje problema, čiščenje podatkov, izbor atributov, opis podatkov ...);
- analiza podatkov (statistična analiza podatkov, strojno učenje, podatkovno rudarjenje, vizualizacija podatkov ...) ter
- ocenitev in uporaba odkritih vzorcev (predstavitve in ovrednotenje rezultatov).

4.3 Proces odkrivanja znanja v podatkih

V prejšnjem poglavju sem opredelila, da je podatkovno rudarjenje le del procesa odkrivanja znanja v podatkih (angl. »*knowledge discovery in databases*«, krajše KDD). Sam KDD proces je natančno opredeljen in sestavljen iz več korakov, ki si sledijo v točno določenem zaporedju. Kako so opredeljeni koraki je odvisno od izbrane metodologije, sama sem si za potrebe magistrskega dela izbrala CRISP-DM metodologijo, ki mi bo pomagala pri samih postopkih priprave in izvedbe podatkovnega rudarjenja. Shema CRISP-DM metodologije je prikazana v shemi na naslednji strani (glej sliko 4.1).

Slika 4.1: Shema CRISP-DM metodologije.



Vir: Prirejeno po Chapman in drugi (2000, 10).

Temelje za CRISP-DM metodologijo so leta 1996 postavila podjetja SPSS, NCR ter DaimlerChrysler. Metodologija ni bila razvita na osnovi teorije in akademskega dela, temveč je nastala in se testirala v praksi. Tako je nastal objektivni in standardni model, ki je uporaben na različnih industrijskih področjih in ohranja nevtralen pogled do orodij za podatkovno rudarjenje (Chapman in drugi 2000, 1–2). Gre za širši pogled na podatkovno rudarjenje (kot je definiran v Fayyad in drugi 1996b). CRISP-DM metodologija podatkovno rudarjenje obravnava kot KDD proces.

Metodologija zahteva, da se odkrivanje znanja odvija kot projekt, sestavljen iz šestih korakov. Od poslovnega problema in od podatkov je odvisno, ali izvedemo čisto vse korake in ali je potrebno korake ponavljati. Vračanje je potrebno na vsakem koraku, kjer ugotovimo, da dosedanje delo ni dalo želenih rezultatov.

Opredelitev posameznih korakov (Chapman in drugi 2000):

1. Razumevanje poslovnega problema: razumevanje ciljev projekta in zahtev iz poslovnega zornega kota (določitev poslovnih ciljev, ocena trenutnega stanja, cilji podatkovnega rudarjenja, izdelava projektnega načrta). Podatkovni analitik mora zelo dobro poznati in razumeti uporabnikove zahteve – na tem koraku se poslovni cilji prevedejo v strokovni jezik. Npr. »poznavanje zvestih kupcev« prevedemo v »izdelaj profil zvestih kupcev, kjer je zvestoba definirana glede na število nakupov in ustvarjeno prodajno vrednost, po demografskih spremenljivkah (spol, starost, kraj bivanja, izobrazba)«.
2. Razumevanje podatkov: zbrane podatke moramo raziskati oziroma jih podrobno preučiti. Preučevanje zajema vse aktivnosti, ki nam omogočajo razumevanje podatkov in ocenitve kvalitete podatkov (vizualizacija, osnovne statistične analize, pregled porazdelitev, obravnava manjkajočih vrednosti, obravnava ekstremnih vrednosti, pregled ključnih povezav med atributi ...).
3. Priprava podatkov: zajema vse aktivnosti, ki so potrebne, da pripravimo končno množico podatkov za vhod v tehnike podatkovnega rudarjenja. Podrobneje je ta korak opisan v naslednjem poglavju (glej poglavje 4.4).
4. Modeliranje: izbor tehnike podatkovnega rudarjenja (v poglavju 4.6 so opisane posamezne tehnike), načrt modeliranja ter izdelava modelov. Pogosto za reševanje poslovnega problema uporabimo več tehnik podatkovnega rudarjenja. Zato je na tem koraku pomembno, da preverimo, ali oblika podatkov zadostuje izbrani tehniki, če ne, se vrnemo na korak priprave podatkov.
5. Ovrednotenje (evalvacija): vrednotenje rezultatov (ocena razmerja med uspehom podatkovnega rudarjenja in poslovnimi cilji) in določitev naslednjih korakov (potrditev modela ali pa vračanje na prejšnje korake). Ko je model zgrajen je potrebno testiranje točnosti vsakega zgrajenega modela, analitično in s poslovnega vidika. Poslovno model ocenimo s stopnjo doseganja poslovnega cilja in poskušamo ugotoviti poslovne razloge za morebitno pomanjkljivost modela. Vsak model ocenimo tudi z analitičnega vidika – katero metodo bomo izbrali je odvisno od same tehnike podatkovnega rudarjenja s katerim smo zgradili model. V tem koraku nas torej zanima, kako dobro model rešuje poslovni problem, ocenimo doprinos projekta in sprejmemo odločitev o potrditvi ali zavrnitvi modela.

6. Uporaba odkritega znanja: model uporabimo v poslovnem okolju ter pripravimo strategijo uporabe novega znanja in spremljanja rezultatov uporabe (načrt razvoja projekta, načrt spremljanja in vzdrževanja projekta, končno poročilo in predstavitev projekta, revizija projekta). Sam proces KDD se ne konča z izgradnjo modela. Znanje, ustvarjeno skozi proces KDD, je potrebno primerno organizirati in predstaviti vodstvu podjetja in uporabnikom novega znanja. Zadnji korak zajema vse aktivnosti, ki so potrebne, da bo zgrajen model tudi dejansko uporabljen, kot ponavljajoč proces znotraj podatkovnega rudarjenja (noben model ni statičen, vsak model je potrebno po določenem času ponovno oceniti in po potrebi prilagoditi na novo nastali situaciji).

4.4 Priprava podatkov za podatkovno rudarjenje

Priprava podatkov za podatkovno rudarjenje je najdaljši proces znotraj KDD-ja in lahko vzame tudi do 90 % celotnega časa (Pyle 1999). Priprava podatkov vključuje naslednje korake (Pyle 1999; Podgorelec 2001):

- Izbira in vzorčenje podatkov: kadar imamo na razpolago ogromne količine podatkov se pogosto v realnosti izkaže, da jih praktično ni mogoče obdelati (omejitve diska, omejitve programske opreme za podatkovno rudarjenje – čas iskanja rešitve je predolg ...), zato naključno izberemo samo vzorec podatkov (objektov) in filtriramo attribute, ki jih ne potrebujemo za analizo. Postavi se vprašanje: koliko podatkov uporabiti; kdaj je vzorec dovolj velik? Za podatkovno rudarjenje lahko uporabimo že zelo majhno podatkovno bazo (manj kot 30 objektov), vendar se je potrebno zavedati, da karkoli izpeljemo iz vzorca, ki ne predstavlja populacije, ne smemo upoštevati kot reprezentativno (Pyle 1999). Sama se strinjam z Brumnom (Brumen 2004, 30), ki poudarja, da je potrebna količina podatkov odvisna tudi od problema podatkovnega rudarjenja.
- Čiščenje/predobdelava podatkov – proces raziskave podatkov: pregled osnovnih statistik in porazdelitve podatkov, obravnava ekstremnih vrednosti, obravnava manjkajočih podatkov, pretvorba podatkov v primeren format. Za podatkovno rudarjenje se pričakuje, da so podatki očiščeni²³. Namen čiščenja podatkov je odstranitev kakršnih koli anomalij, ki bi lahko zmanjšale učinkovitost izbrane tehnike

²³ Čistost podatkov pomeni, da so podatki primerni za vhod v izbrani model za podatkovno rudarjenje, torej so primerne formata, brez manjkajočih vrednosti in odstranjene so vse anomalije.

podatkovnega rudarjenja (npr. odločitvena drevesa so zelo odvisna od čistosti podatkov).

- Transformacija in redukcija podatkov: v mnogih primerih za končni rezultat niso potrebni vsi atributi, ki opisujejo objekte v množici podatkov (izločimo nepotrebne attribute); zelo pogosto je podatke potrebno transformirati oz. pretvoriti v najprimernejšo obliko za uporabo izbrane tehnike podatkovnega rudarjenja (npr. transformacija podatkov na nivoju artikla oziroma posamezne pozicije, kjer je ena vrstica na računu en artikel, v seštevek na računu – seštejemo število prodanih artiklov na računu).
- Za potrebe modeliranja je potrebno razbiti celotno množico podatkov na učno množico podatkov (angl. »*training data set*«, npr. 70 %) za učenje modela in testno množico podatkov (angl. »*testing data set*«, npr. 30 %) za analitično testiranje točnosti modela (Bramer 2007, 80).

Kako pripraviti podatke, da bodo v primerni obliki za podatkovno rudarjenje je odvisno od ciljev in nalog podatkovnega rudarjenja, ki jih pojasnim v naslednjem poglavju.

4.5 Cilji in naloge podatkovnega rudarjenja

Cilji podatkovnega rudarjenja:

- Opis podatkov oziroma opisno podatkovno rudarjenje – cilj je razumevanje odkritih vzorcev.
- Model podatkov oziroma podatkovno rudarjenje z napovedovanjem – cilj je posplošitev modela na osnovi trenutnih podatkov za uporabo na bodočih podatkih.

Pri podatkovnem rudarjenju z napovedovanjem (osnovna teoretična referenca: Weiss in Indurkha 1998) je model zgrajen na trenutnih (danih) podatkih, uporabljen pa na novih podatkih s ciljem napovedi (ali ocenitve) neznane (ciljne) vrednosti. Zgradimo torej model, ki na osnovi več neodvisnih atributov (npr. demografije), določi vrednost odvisnega atributa (zvesti kupec: da/ne). Na primer – v ciljanem trženju je za izgradnjo modela uporabljena podatkovna baza zvestih kupcev v okviru programa zvestobe, nato je ta model uporabljen na podatkih novega kupca, za napoved, ali bo le-ta postal zvesti kupec.

Za proces izgradnje modela v magistrskem delu uporabljam termin »modeliranje«, pri čemer množica primerov z že znanimi rešitvami predstavlja učne objekte, na podlagi katerih zgradimo model, ki vsebuje naučeno znanje in s pomočjo katerega lahko sklepamo o rezultatih novega testnega primera (Lavrač 2007).

Opisno podatkovno rudarjenje uporabimo za razumevanje podatkov. Pogosto je bolj pomembno imeti opis vzorcev v podatkih (npr. grafična predstavitev in osnove opisne statistike), kot zelo natančen model. Gre za iskanje zanimivih skupin in pogostih vzorcev v podatkih, z namenom odkrivanja znanja v podatkih. Primer odkrivanja in opisa novih vzorcev v ciljanem trženju je analiza nakupne košarice (prodanih artiklov).

Naloge podatkovnega rudarjenja (Berry in Linoff 1997, 51–62):

- klasifikacija (uporablja se tudi sinonim *uvrščanje*; angl. »*classification*«),
- ocenitev (angl. »*estimation*«),
- napoved (angl. »*prediction*«),
- asociacije (angl. »*association*«),
- razvrščanje (uporabljajo se tudi sinonimi *rojenje*, *grupiranje* ali *grozdenje*; angl. »*clustering*«),
- opisovanje (angl. »*description*«) in vizualizacija (angl. »*visualization*«).

Klasifikacija je ena izmed najbolj pogostih nalog podatkovnega rudarjenja. Pri klasifikaciji učne enote uvrstimo v vnaprej dane skupine (definirane s strani poslovnih uporabnikov ali pa naučene iz podatkov – primerov rešenih problemov v preteklosti), imamo torej odvisni atribut. Nastale skupine lahko uporabimo za razumevanje že obstoječih podatkov ali za napoved na novih podatkih. Na učni množici iz zgodovinskih podatkov zgradimo model, ki ga nato uporabimo na novi testni množici za napoved definirane skupine (npr. kupec/ne-kupec). Gre torej za nadzorovano učenje, kjer enote najprej uvrstimo v vnaprej dane skupine in šele nato odkrivamo skupne značilnosti skupin. Zelo pomembno je, da so dane skupine zelo natančno definirane. Primer uporabe klasifikacije v ciljanem trženju je uvrstiti novega kupca v »zlato«, »srebrno« ali »bronasto« skupino kupcev po ustvarjeni potrošnji. Za klasifikacijo se zelo pogosto uporabijo tehnike odločitvenih dreves in algoritmi, ki ustvarijo množico ČE-POTEM pravil (klasifikacijska pravila).

Naloga *ocenitve* je zapolnitev manjkajoče vrednosti v določenem polju atributa s funkcijo drugih polj v atributu. Za attribute z manjkajočimi vrednostmi uporabljamo ocenitev, da pridobimo vrednosti za neznana polja. Na primer – pri analizi članov programa zvestobe, kadar imamo pri atributu starost manjkajoče vrednosti, lahko le-te nadomestimo z ocenjenimi vrednostmi. Ocenjevanje je zelo podobno razvrščanju – ciljni atribut je numerični in ne kategorični. Za ocenjevanje se zelo pogosto uporabi linearna regresija ali regresijsko odločitveno drevo.

Napoved se razlikuje od ocenitve in od razvrščanja v tem, da so objekti razvrščeni glede na neko napovedano prihodnje obnašanje ali ocenjeno prihodnjo vrednost. Za napovedovalno podatkovno rudarjenje je torej značilno, da morajo biti dogodki z znanimi rezultati na razpolago – model zgradimo na osnovi množice učnih objektov z že znanimi rešitvami (Weiss 1998). Bistveno pri napovedi je, da moramo počakati na dejanske rezultate in jih (šele kasneje) primerjati z napovedanimi (Berry in Linoff 1997, 10). Na primer – pri analizi članov programa zvestobe, napovedni model za odhod oziroma izgubo kupca (angl. »*churn model*«).

Asociacije – na splošno gre za analizo asociacij oziroma odkrivanja atributov, »ki gredo skupaj«. Pri asociacijah nimamo določenega odvisnega atributa (vsak atribut je lahko odvisen ali neodvisen), gre torej za nenadzorovano učenje (Kononenko 2005, 11–13). Posebna pristopa k asociacijam so asociativne nevronske mreže (pogosto se uporabljajo pri problemih prepoznavanja, kjer je prepoznan samo del podatkov in je potrebno prepoznati celoto, npr. kadar je potrebna rekonstrukcija obraza) in povezovalna pravila (namen algoritma je iskanje zanimivih relacij med atributi, ki lahko doprinesejo zanimiva ter nova spoznanja o samih podatkih oziroma o zakonitostih na obravnavanem problemskem področju). Analiza asociacij se v ciljanem trženju uporablja predvsem pri analizi nakupne košarice in pri analizi podatkov iz transakcij.

Razvrščanje se od klasifikacije razlikuje v tem, da ne poznamo skupin vnaprej, gre torej za nenadzorovano učenje (nimamo odvisnega atributa). Naloga razvrščanja je razbiti množico enot na manjše značilne skupine (uprabljajo se tudi sinonimi: razrede, grupe, grozde, roje), za katere mora veljati čim večja homogenost znotraj skupin in heterogenost med skupinami. Algoritem na osnovi neodvisnih atributov izdela odvisni atribut, ki ga mora interpretirati strokovnjak (poslovni uporabnik), ki ima znanje s področja obravnavanega problema (Weiss 1998). Značilnost razvrščanja je tudi v tem, da ni rezultata, s katerim bi opravili primerjavo.

Primer iz ciljanega trženja, je razvrščanje članov programa zvestobe v skupine na osnovi vedenjskih atributov.

Algoritmi za razvrščanje uporabljajo enega od treh osnovnih pristopov (Kononenko 2005):

- Od spodaj navzgor (hierarhične metode razvrščanja: v praksi se najpogosteje uporablja algoritem Ward): na začetku je vsak objekt svoja skupina. Algoritem nato združuje najbolj podobne skupine med seboj (glede na izbrano mero podobnosti), dokler ne ostane ena sama skupina, v kateri so združeni vsi objekti. Nato strokovnjak sam (npr. na osnovi dendograma²⁴ ali poznavanja poslovne vsebine) določi število končnih skupin.
- Od zgoraj navzdol (hierarhične metode razvrščanja: metode cepitve): na začetku vsi objekti pripadajo eni sami skupini. Zatem algoritem razbija skupine na podskupine, dokler ne doseže želenega števila skupin.
- Na začetku se naključno izbere n objektov kot nosilce objektov, kjer je n želeno število objektov (kombinacija hierarhičnih – za izbor števila razredov in ne-hierarhičnih – za končno razvrščanje, metod razvrščanja). Zatem se vsi objekti (glede na podobnost) razvrstijo v enega od n razredov (najpogosteje je uporabljen algoritem metode voditeljev). Cel postopek se ponavlja, dokler niso razredi zadovoljivo koherentni.

Pogosto nas ne zanimajo modeli zgrajeni na podatkih (predvsem kadar je rezultate potrebno predstaviti vodstvu podjetja), temveč želimo le »videti« podatke, jih *opisati ali vizualizirati*. Grafična predstavitev množice podatkov je izjemno pomembno orodje pri odkrivanju znanja v podatkih – omogoča nam boljše razumevanje podatkov ter vsebovanih zakonitosti (Leban 2007). Ključne prednosti: intuitivnost in enostavnost za uporabnika; ne zahteva posebnega razumevanja kompleksnih matematičnih ter statističnih algoritmov; interpretativnost – odkrite zakonitosti dejansko vidimo; stroškovno zelo učinkovita in zanesljiva metoda ... Pomaga nam odkriti vzorce v podatkih, ki bi jih z drugimi (kompleksnejšimi) metodami verjetno spregledali.

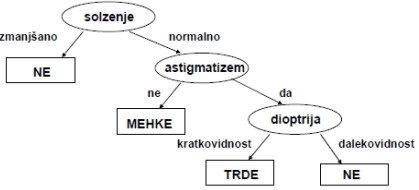
²⁴ Dendogram (uporablja se tudi sinonim *drevo razvrščanja*) je prikaz, kako so se združevali objekti in skupine skozi ves proces razvrščanja. Listi dendograma so objekti, točke združitve pa sestavljene skupine (Ferligoj 1989, 68).

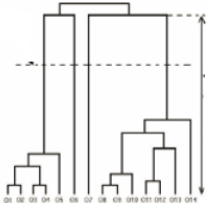
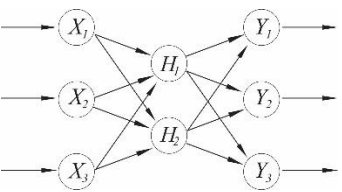
Za reševanje istih nalog (problemov) lahko uporabim različne tehnike (pristope) podatkovnega rudarjenja, ki jih na kratko opredelim v naslednjem poglavju. Več pozornosti posvečam samo tehnikam, ki jih bom uporabila v empiričnem delu magistrskega dela. Na splošno v literaturi ni postavljenih kriterijev, katere metode uporabiti za reševanje določenih nalog (Fayyad 1996; Weiss in Indurkha 1998; Seng in Chen 2010). Sama se bom v magistrskem delu držala načela, da je najprej potrebno preizkusiti preproste tehnike (tako s stališča algoritma, kot intuitivnega razumevanja s strani poslovnih uporabnikov). To načelo odseva princip Occamove britve (angl. »Occam`s razor«), ki med več modeli – ki enako točno ustrezajo danim podatkom – daje prednost najbolj enostavnemu med njimi (Bishop v Podgorelec 1995, 14; Kononenko 2005). Cilj mi je torej najti kar najbolj enostaven možen model, ki ustreza podatkom, saj je takšen model običajno najbolj smiseln in enostaven za interpretacijo, kar je še posebej pomembno, saj nameravam model predstaviti vodstvu podjetja Engrotuš d.d. in Studia Moderna d.o.o..

4.6 Tehnike podatkovnega rudarjenja

Na kratko opredelim pogostejše tehnike podatkovnega rudarjenja v spodnji tabeli (glej tabelo 4.1).

Tabela 4.1: Hiter pregled najpogostejših tehnik podatkovnega rudarjenja.

TEHNIKA	TIP NALOGE	OPISNI JEZIK	PRIMER
Klasifikacijska pravila	Napovedovanje in klasifikacija	Pravila $X \rightarrow R$, če X potem R (X = množica vrednosti atributov; R = razred)	Primer kontaktne leče: solzenje = zmanjšano \rightarrow leče = NE
Odločitvena drevesa	Napovedovanje in klasifikacija	Odločitvena drevesa (grafična predstavitev ter izpis pravil): notranja vozlišča = atributi; veje = vrednosti atributov; listi = razred.	Primer kontaktne leče: 
Povezovalna pravila	Opisovanje in analiza nakupne košarice	Pravila $X \rightarrow Y$, če X potem Y (X, Y = množica postavk – binarnih atributov) Podpora: $Po(X,Y) = \#XY/\#D = p(X,Y)$ Zaupanje: $Za(X,Y) = \#XY/\#X = p(X,Y)/p(X) = p(Y X)$	Primer kontaktne leče: zmanjšano solzenje = NE \rightarrow astigmatizem = normalno (0,50; 0,75)

TEHNIKA	TIP NALOGE	OPISNI JEZIK	PRIMER
Odkrivanje podskupin z učenjem pravil	Opisovanje, klasificiranje, razvrščanje in napovedovanje	Opisi »zanimivih« podskupin primerov v obliki kratkih, človeku razumljivih pravil, ki: <ul style="list-style-type: none"> - pokrivajo čimveč učnih primerov; - imajo čimbolj različno porazdelitev vrednosti ciljnega atributa glede na učno množico. 	Primer odkrivanja podskupin: <ul style="list-style-type: none"> - Nesreča je težka ali smrtna, če je bilo v nesreči poškodovano le eno vozilo. - Nesreča je lahka, če je bilo v nesreči poškodovanih več vozil (>2) in malo poškodovanih oseb.
Naivni Bayesov klasifikator	Napovedovanje in klasifikacija	Verjetnost razreda (c) pri danih vrednostih atributov (a_i): $P(c a_1, a_2, \dots, a_n) = P(c) \prod_i \frac{P(c a_i)}{P(c)}$	Primer: Ali bo pajek ponoči ujel mravljo, ki je bele barve? $P(c) = 0,25$ c = DA (ujel jo bo) $a_1 = \text{»čas = noč«}$; $a_2 = \text{»barva = bela«}$
Hierarhično razvrščanje v skupine	Razvrščanje	Grafični prikaz, ki kaže kako objekti padejo v skupine – dendrogram. Rezultat je število skupin in za vsak objekt pripadnost skupini.	Primer dendrograma: 
Najbližji sosed (angl. »nearest neighbors«)	Klasifikacija, ocenjevanje in napovedovanje	Rezultat je za vsak nov objekt uvrstitev v razred, ki mu pripada največ bližnjih sosedov (najbolj podobnih primerov).	Primer v medicini: zdravnik mora novemu bolniku predpisati zdravilo. Rezultat je »najbližji sosed«, bolnik (zgodovinski podatki) z najbolj podobnim profilom. Zdravilo »najbližjega sosedu« bo sedaj predpisal novemu bolniku.
Nevronske mreže	Napovedovanje, klasifikacija, prepoznavanje vzorcev (asociacije)	Shematičen prikaz nevronske mreže: vhodni nevroni = atributi (eden ali več nivojev skritih nevronov); izhodni nevroni = razredi. Naloga algoritma je postaviti uteži na povezavah med nevroni tako, da bo klasifikacijska napaka čim manjša.	Primer trinivojske umetne nevronske mreže s tremi vhodnimi nevroni, dvema skritima in tremi izhodnimi nevroni. 
Regresijski modeli	Napovedovanje in klasifikacija	Rezultat je napovedana vrednost odvisnega atributa pri izbranih vrednostih neodvisnega atributa. ($Y = \alpha + \beta X + \epsilon$; koef. determinacije; standardna napaka regresije; intervali zaupanja za napovedi).	Primer: želimo napovedati višino 40 in 5 let starega človeka: višina (40 let) = 1,61 m višina (5 let) = 1,53 m

Vir: Berry in Linoff (1997); Kavšek (2004); Kononenko (2005); Lavrač (2007); Kononenko in Kukar (2007); Kralj (2007b).

Spodaj podrobneje opišem tehniko podatkovnega rudarjenja, ki sem jo uporabila v empiričnem delu magistrskega dela.

Povezovalna pravila

Povezovalna pravila (Agrawal in drugi 1993; Agrawal in Srikant 1994; Demšar 2000; Kononenko 2005; Witten in Frank 2005; Tan in drugi 2006; Kralj, 2007a; Raeder in Chawla 2011) so pravila oblike $X^{25} \rightarrow Y^{26}$, kjer sta X in Y množici vrednosti binarnih atributov (vrednosti 1/0 oziroma DA/NE)²⁷. Če velja leva stran (npr. kupec je kupil artikel X), velja tudi desna stran (kupil je artikel Y) – nasprotno seveda ni nujno. Namen učenja povezovalnih pravil na bazi podatkov je iskanje zanimivih povezav med atributi, ki lahko doprinesejo zanimiva (nova) spoznanja o samih podatkih oziroma o zakonitostih v dani problemski domeni. Algoritem išče objekte, ki implicirajo prisotnost drugih objektov v isti transakciji. Če to prevedem v problem analize nakupne košarice, to pomeni, da algoritem išče povezave med artikli. Povezave med artikli zapišem kot povezovalno pravilo. Analiza košarice je torej raziskovanje povezovalnih pravil oziroma zakonitosti, ki pokažejo artikle, ki se pogosto pojavljajo skupaj v nakupni košarici.

V vsaki podatkovni bazi je povezovalnih pravil ogromno, vendar niso vsa enako zanimiva. Naloga učnega algoritma je poiskati vsa povezovalna pravila, ki so dovolj pogosta, kar izračunam s **podporo** (okrajšano Po; angl. »*support*«) in zanesljiva oziroma točna, kar izračunam z **zaupanjem** (okrajšano Za; angl. »*confidence*«). Podpora določa kako pogosto je pravilo uporabljeno na množici podatkov, medtem ko zaupanje pove, kako pogosto se objekti iz množice Y pojavljajo v transakcijah, ki vsebujejo objekt X. Pri ocenjevanju povezovalnih pravil si pomagam tudi z **izboljšavo** (okrajšano Iz; angl. »*lift, improvement*«), ki mi pove, koliko boljše je pravilo pri napovedovanju, kot bi bila naključna izbira (določa napovedno vrednost pravila). Definicija vseh treh meril je podana v sliki na naslednji strani (glej sliko 4.2), kjer je D število vseh računov (oziroma nakupnih košaric). Obstajajo še druga merila²⁸ za oceno zanimivosti odkritih povezovalnih pravil (oziroma odkritega novega znanja). Številne raziskave na področju razvoja ocen zanimivosti povezovalnih pravil (Klemettinen in

²⁵ Predpogoj, predhodnik ali antecedent (angl. »*antecedent*« ali »*left-hand side*«).

²⁶ Popogoj, poslednik, konsekvent ali desno-ročna stran (angl. »*consequent*« ali »*right-hand side*«).

²⁷ (artikel je bil kupljen /artikel ni bil kupljen).

²⁸ Za podroben pregled vseh meril glej članek »*Selecting the right objective measure for association analysis*« (Tan in drugi 2004).

drugi 1994; Dong in Li 1998; Liu in drugi 2000; Tan in drugi 2004; McGarry 2005; Geng in Hamilton 2006; Li 2006; Lenca in drugi 2008) si delijo skupen zaključek, da nobena mera ni najboljša za vsako problemsko področje, zato je na strani uporabnika za katero mero se bo odločil. Sta pa podpora in zaupanje tisti meri, ki sta najpogosteje uporabljene.

Slika 4.2: Definicija podpore, zaupanja in izboljšave.

Podpora: $Po(X,Y) = \#XY/\#D = p(X,Y)$
Zaupanje: $Za(X,Y) = \#XY/\#X = p(X,Y)/p(X) = p(Y X)$
Izboljšava: $Iz(X,Y) = \#XY/(\#X\#Y) = p(X,Y)/(p(X) p(Y))$

Razlago povezovalnih pravil bom ponazorila s primerom analize nakupne košarice, s poenostavljeno vhodno tabelo (glej tabelo 4.2).

Tabela 4.2: Poenostavljen primer nakupne košarice.

ID nakupne košarice	Limone	Por	Bučke	Jabolka
1	1	0	0	1
2	1	1	1	0
3	0	1	1	0
4	0	1	0	1
5	1	0	0	1
6	0	1	0	1

Povezovalna pravila so mera pogostosti pojavljanja določenih vzorcev v podatkovnih množicah – v pričujočem primeru na množici nakupnih košaric v tabeli 4.2. Iz tabele je razvidno, da se npr. pojavljata skupaj v košarici artikla *por* in *bučke* – večkratnim pojavitvam enakih vzorcev pravim pogosti vzorci, ki so osnova za izgradnjo povezovalnih pravil. Pravilo *por* → *bučke* [podpora = $2/6 = 33,3\%$; zaupanje = $2/4 = 50\%$; izboljšava = $3/2 = 1,5$] pomeni, da če se v nakupni košarici pojavlja artikel *por*, se v večini primerov nahaja tudi artikel *bučke*. Takšno pravilo pa seveda ne velja vedno. Podpora izraža kako pogosto se vzorec *por* → *bučke* pojavlja v podatkovni množici. Zaupanje pa izraža kako pogosto se bučke pojavljajo v nakupnih košaricah, ki vsebujejo por. Zaupanje lahko prevedem tudi v pogojno verjetnost: če se v nakupni košarici nahaja *por*, kakšna je verjetnost, da bodo v nakupni košarici tudi *bučke*? Torej v konkretnem primeru velja: »če se v nakupni košarici

nahaja *por*, se v 50 % primerih nahajajo tudi *bučke* – to se zgodi v 33,3 % primerov izmed vseh nakupnih košaric. Izboljšava je pravzaprav korelacija, zato v primeru če bi dobila vrednost manjšo od 1, bi bilo bolj veljavno pravilo $X \rightarrow \text{ne } Y$, oziroma $\text{por} \rightarrow \text{ne bučke}$. V konkretnem primeru za izboljšavo dobim vrednost 1,5, torej večjo od 1. Kar – npr. za trženjske aktivnosti pomeni – da je bolje, da zraven pora kot dodaten artikel ponudijo bučke, kakor, da bi dodaten artikel izbrali slučajno.

V realnih primerih so podatkovne množice, na katerih se iščejo povezovalna pravila, zelo velike – z ogromno pogostih vzorcev. Zato je za iskanje povezovalnih pravil potreben avtomatski algoritem. Učinkovit algoritem za iskanje povezovalnih pravil je algoritem APriori (Agrawal in drugi 1993; Agrawal in Srikant 1994), ki sestoji iz dveh korakov: najprej poišče vse pogoste vzorce (ob dani podpori in zaupanju – s strani uporabnika) v dani podatkovni množici, nato iz njih ustvari povezovalna pravila. V prvem koraku algoritem najprej uredi attribute po nekem vrstnem redu (npr. po abecednem), kar olajša preverjanje identičnosti vzorcev. Nato ustvari vse i – terice vzorcev z dovolj veliko podporo. S prvim prehodom skozi celotno podatkovno množico poišče vse 1 – vzorce (eno atributne vzorce, $i = 1$), ki imajo dovolj veliko podporo oziroma ustrezajo pogoju minimalne podpore. Z drugim prehodom skozi podatkovno množico (tukaj ni več potrebno, da gre skozi celotno podatkovno množico, saj so vsi 1 – vzorci z dovolj veliko podporo že ustvarjeni in shranjeni) poišče 2 – vzorce (dvo-atributne vzorce, $i = 2$), ki imajo dovolj veliko podporo. Postopek se nadaljuje (za vsak i je potreben en prehod preko podatkovne množice) dokler ne postane množica $(i + 1)$ – vzorcev prazna, s tem se prvi korak algoritma zaključi. V drugem koraku iz vsake tako dobljene množice i – vzorcev izpelje sva možna pravila, pri čemer na vsakem i prehodu obdrži samo pravila z dovolj velikim zaupanjem oziroma tista, ki ustrezajo pogoju zahtevane točnosti (zaupanja). Za optimizacijo prehodov skozi podatkovno množico algoritem upošteva naslednjo omejitev: če velja za pravilo $A \rightarrow B \& C$, da presega prag minimalne podpore, potem isto velja za pravili $A \& B \rightarrow C$ ter $A \& C \rightarrow B$. Ta omejitev služi za učinkovito ustvarjanje pravil.

Vendar še vedno, zaradi velikega prostora, ki ga je potrebno preiskati za izdelavo povezovalnih pravil, obstaja veliko variant osnovnega algoritma APriori, ki poskušajo pohitriti osnovni algoritem – z minimiziranjem števila kandidatov, ki jih je potrebno pregledati ter z minimiziranjem časa za izračun frekvence (pogostosti) za posameznega kandidata (Kononenko 2005).

Zelo redko se povezovalna pravila iščejo na najnižjem nivoju, nivoju artikla. Ne samo zaradi ogromnega števila pravil, temveč tudi vsebinsko sklepamo, da bodo povezovalna pravila boljša na višjem nivoju (nivoju blagovne skupine), kajti razpršenost podatkov je manjša. In tudi v praksi (vsaj v primeru trgovca) v veliki večini ni smiseln najnižji nivo (npr. »gel za prhanje Duschdas Magnolia«), saj se najpogosteje v primeru kuponov nudijo popusti na višjem nivoju (npr. vsi »geli za prhanje Duschdas«)²⁹. Lahko pa hkrati preverjamo pravila na več nivojih (t.i. več nivojska pravila) in tako nadgradimo analizo. Prav tako APriori algoritem deluje samo na diskretnih atributih, v kolikor imamo zvezne attribute je le-te potrebno predhodno diskretizirati. Povezovalna pravila namreč niso uporabna le v primeru analize nakupne košarice, temveč jih lahko nadgradimo z dodatnimi atributi (npr. spol kupca, starost po razredih ...) in jih tako uporabljamo tudi za potrebe segmentacije (Lent in drugi 1997). Večnivojska pravila tako nadgradimo z iskanjem večdimenzionalnih povezovalnih pravil.

Pri analizi povezovalnih pravil lahko odkrijemo nova znanja, ki nam na prvi pogled ne predstavljajo logičnih povezav in nanj gledamo kot na neznanje, vendar se ravno v teh »nesmiselnih« povezavah lahko skrivajo nova spoznanja. Prav tako je zahteven problem ugotoviti, kaj predstavlja novo znanje in kako ga ločiti od že znanega znanja, zato je človeški dejavnik pri iskanju novega znanja ključnega pomena.

²⁹ Primer trgovca Tuš – kupon » -50 % popust na vse gele za prhanje DUSCHDAS« iz kataloga z veljavnostjo 24. 2. 2016–29. 2. 2016.

4.7 Odkrivanje znanja v poslovnem okolju

Podatkovno rudarjenje je uporabno na različnih področjih – od poslovnih do znanosti: bančništvo in finance (analiza komitentov, investicij, obravnavanje posojil, kreditna tveganja, zlorabe kreditnih kartic ...); zavarovalništvo (analiza strank, odkrivanje zlorab ...); telekomunikacije (analiza socialnih omrežij); medicina in zdravstvo (napovedovanje stroškov hospitalizacije, odkrivanje novih diagnostičnih dejavnikov, za določanje zdravil bolnikom ...); znanosti o okolju (ocenjevanje onesnaženosti voda, onesnaženosti ozračja, napovedovanje povečanja gozdnih površin ...); biologija (identifikacija na tisoče genov v vsakem genomu ...); astronomija (izgradnja avtomatiziranega sistema katalogiranja nebeških objektov, ki jih z vizualnim nadzorom ne moremo zaznati ...); trgovina (organizacija ponudbe v samopostrežnih trgovinah, določitev lokacije nove trgovine, analiza dobrih strank – kako zadržati stranko, kako ji ponuditi dodatne usluge, kako identificirati potencialne kupce za kataloško prodajo, analiza nakupne košarice ...).

V poslovnem okolju ima podatkovno rudarjenje veliko dodano vrednost prav v ciljanem trženju, kjer ogromne količine podatkov pretvorimo v novo ter uporabno znanje. Za vsako podjetje, ki je po svoji strategiji osredotočeno na kupca, je ključnega pomena dobro poznavanje svojih kupcev in sposobnost, da se hitro in učinkovito odzovejo na njihove potrebe – sposobnost poslati pravo ponudbo pravemu kupcu ob pravem času po pravi ceni po primerni tržni poti oziroma komunikacijskemu kanalu (Berry in Linoff 2000, 80). Gre torej za osnovni problem ciljanega trženja, ki ga lahko rešujemo z metodami podatkovnega rudarjenja. Izkoriščanje znanja, pridobljenega iz lastnih podatkov, ter po možnosti povezovanje teh podatkov iz zunanje pridobljenih podatkov (npr. tržne analize, podatki iz statističnega urada ...), pomeni za podjetje konkurenčno prednost.

V nadaljevanju predstavljam primere uporabe metod podatkovnega rudarjenja v poslovnem okolju trgovca, v okviru programa zvestobe.

4.7.1 Odkrivanje znanja v poslovnem okolju trgovca – v okviru programa zvestobe

Spodaj naštejemo nekaj najbolj pogostih primerov uporabe metod podatkovnega rudarjenja v poslovnem okolju trgovca – v okviru programa zvestobe. V tem razdelku uporabljamo izraz *kupec*, za vse kupce, ki jih je zmožen trgovec enoznačno identificirati. Najpogosteje lahko trgovci identificirajo samo člane programa zvestobe (npr. Engrotuš d.d., Mercator d.d., Spar Slovenija d.o.o.), vendar ni temu vedno tako (trgovec lahko zbira kontaktne podatke tudi za kupce, ki se ne želijo pridružiti programu zvestobe, npr. Studio Moderna d.o.o.).

Raziskovanje vedenja kupcev

Za uresničevanje strategije osredotočenosti na kupca, je ključno poznavanje vedenja kupcev (Khodakarami in Chan 2014; Ho in drugi 2015), le-to znanje si trgovec pridobi s tehnikami opisnega podatkovnega rudarjenja. Raziskovanje se običajno začne s preučevanjem demografskih in socioekonomskih značilnosti kupcev (osnovne opisne statistike in grafične predstavitve) ter se nadaljuje s preučevanjem vedenja kupcev iz transakcijskih podatkov. Iščejo se odgovori na vprašanja (Vukasović 2013): kaj kupec kupuje (katere artikle, katere blagovne skupine ...); kdaj kupuje (na splošno kdaj nakupuje: ob katerih dnevih, dopoldan/popoldan, kako pogosto; kako pogosto kupi določen artikel/blagovno skupino: dnevno, tedensko, mesečno ...); kje kupuje (v katerih poslovnih enotah), kako kupuje (gotovina, plačilne kartice ...) ter koliko potroši (pri enem nakupu, mesečno, letno ...).

Segmentiranje kupcev in izdelava profilov kupcev

Zaradi velikega števila kupcev, trgovci ne morejo preučiti vsakega kupca posebej ter prav tako ne morejo prilagoditi vsakega artikla vsakemu kupcu posebej. Prav tako ne morejo pričakovati, da imajo vsi kupci enake potrebe, značilnosti ... Ta problem rešujejo tako, da kupce razdelijo v nekaj skupin (v trženju se najpogosteje uporablja izraz *segment*, ne glede ali gre za problem uvrščanja ali razvrščanja) oziroma segmentov, znotraj katerih so si kupci podobni po določenih (najpogosteje vnaprej določenih s strani poslovnega uporabnika) lastnostih ter različni med segmenti (npr. se odzivajo na različne komunikacijske kanale, kupujejo različne blagovne skupine, se razlikujejo v mesečni potrošnji, se odzivajo na različne tipe marketinških akcij ...). Vedenje kupcev preučujejo torej z namenom ugotavljanja skupnih

lastnosti posameznih skupin kupcev – tem skupnim lastnostim pravimo profil. Trženjsko aktivnost (komunikacijski kanal, ponudbo ...) tako prilagodijo segmentu in ne posameznemu kupcu. Ta princip se je izkazal kot stroškovno in organizacijsko zelo učinkovit ter omogoča trgovcu povečevanje zvestobe kupcev. Izdelava profila za posamezen segment kupcev, omogoča trgovcu razumevanje lastnosti segmenta.

V praksi je za vsako podjetje pogosto najbolj uspešno strateško segmentiranje, za katerega je značilno, da ima podjetje segmentiranje zastavljeno kot strateški proces, ki zadeva celotno podjetje in ima natančno določene tudi specifične trženjske strategije za posamezne segmente (Kukovec 2013). Primer v slovenskem okolju so vsi trije vodilni trgovci (Mercator d.d., Spar d.o.o., Engrotuš d.d.), ki izvajajo specifične trženjske aktivnosti za isti segment, t.i. »seniorji«.

Medtem ko so segmentacije, ki temeljijo na nenadzorovanem učenju (na prodajnih podatkih, na nakupnem vedenju ...), pogosto manj učinkovite, predvsem zaradi naslednjih pasti:

- Pogosto je zelo zapleteno opisati značilnosti posameznih segmentov v jeziku poslovnih uporabnikov.
- Nizka stopnja sposobnosti zaposlenih za razumevanje samega postopka izgradnje segmentov (razumevanje metodologije – izračunavanja segmentov).
- Pogosto se zaposleni ne »ponotranjijo« oziroma se ne poistovetijo s segmentom.
- Posledično nizka stopnja sposobnosti prilagajanja aktivnosti ciljanega trženja posameznim segmentom.

Za merjenje zvestobe kupcev se najpogosteje uporablja RFM segmentacija (R: število dni od zadnjega nakupa; F: število nakupov; M: bruto dobiček ali prodajna vrednost; angl. »*recency frequency value segmentation*«). Segmentacija ima naslednje lastnosti: vsi segmenti so izvedljivi, merljivi, stabilni, dovolj veliki in enostavno opisljivi (McCarty 2007; Stafford 2009; Dash in Suryakanta 2010). Prav tako, mora biti prioriteta vsakega trgovca izdelava profila zvestih kupcev lastni blagovni znamki (Martoz-Partal in González-Benito 2013, 349), kot tudi izdelava psihološkega profila (Naghiu 2011, 211).

Odzivnost kupcev

Osnovna ideja pri modeliranju odziva (angl. »*response model*«, na aktivnost ciljanega trženja, npr. na direktno pošto) je izboljšati stopnjo odziva kupcev s ciljanjem le na tiste kupce, ki se bodo nanjo tudi najverjetneje odzvali (Seng in Chen 2010). Poslovne koristi takšnega modeliranja: zmanjševanje stroškov ali ob istih stroških doseči večjo ciljno skupino, povečan dobiček, izboljššan nadzor nad zalogo in upravljanjem dobave, povečevanje zadovoljstva in zvestobe kupcev.

Upravljanje s tveganji

Trгоvec lahko uporablja metode podatkovnega rudarjenja z namenom odkriti prevare (zaposlenih: npr. odkriti trgovke, ki izkoriščajo bonitete in nagrade programa zvestobe v svojo osebno korist in ne v korist kupca; kupcev: npr. kupce z ekstremnim vedenjem, ki odstopa od povprečja) ali ocenitve tveganj (angl. »*risk model*«, npr. poišče kupce, ki kupujejo izključno akcijske artikle – ti kupci se nato izločijo iz ciljanega trženja) (Seng in Chen 2010).

Aktiviranje kupcev

V poslovnem okolju trgovca je izredno pomembno predvideti prekinitev odnosa kupca s trgovcem oziroma prebeg kupca h konkurenci. Zato je potrebno opazovanje zgodnjega vedenja kupcev, ki je lahko dober pokazatelj, kako se bo odnos s kupcem razvijal v prihodnje. Odkrivanje znanja v podatkih omogoča trgovcu vnaprej ugotoviti, kateri kupci nameravajo oditi³⁰ (kateri kupci zmanjšujejo vrednost in pogostost nakupovanja) ter ustrezno ukrepati za ponovno aktivacijo kupcev oziroma pripraviti ovire za izstop iz odnosa (prilagoditi ponudbo, ponuditi dodatne bonitete ...).

Analiza nakupne košarice in vezana prodaja

Ciljano trženje nadgradimo tako, da segmentu kupcev (če ima trgovec na voljo ustrezno tehnologijo, lahko tudi na nivoju posameznega kupca) ponudimo artikle, ki jih kupci pogosto kupujejo skupaj (preiskovanje tipologije in zaporedja). Rezultati analize nakupne košarice

³⁰ Tako imenovan "Churn" model – napovedni model, ki oceni tveganje odhoda za vsakega posameznega kupca.

služijo kot predlogi za ponujanje novih (angl. »*cross-sell*«) in nadgradnjo obstoječih artiklov (angl. »*up-sell*«, »*next best offer*«)³¹ ter predvsem ponujajo boljše razumevanje nakupnih navad kupcev (Raeder in Chawla 2011). Dejanska uporaba pridobljenega znanja pri trženjskih aktivnostih ima za trgovca naslednje posledice: povečevanje prodaje, povečevanje profita, zmanjšanje stroškov ter povečevanje zvestobe kupcev (Seng in Chen 2010).

Analiza nakupne košarice odgovori na tipična vprašanje, ki si jih zastavi vsak trgovec:

- Kateri izdelki se najpogosteje kupujejo skupaj?
- Kateri izdelek bo kupec še kupil v prihodnje?
- Kateri izdelek bo kupec kupil pri naslednjem nakupu?
- Kolikšna je verjetnost, če kupec kupi izdelek A, da bo kupil tudi izdelek B?
- Katere izdelke postaviti skupaj na prodajne police?

Rezultati analize nakupne košarice so torej informacije z veliko potencialno vrednostjo (Chen in drugi 2005) za načrtovanje novih oziroma optimiziranje obstoječih ukrepov sistematičnega pospeševanja prodaje. Trgovci tako pridobljeno znanje uporabijo za pridobivanje novih in zadrževanje najbolj zvestih kupcev ter za povečevanje vrednosti obstoječih kupcev z individualizacijo ponudbe ali z vezano prodajo. Prava vrednost vezane prodaje se pokaže, ko je trgovec sposoben odkriti skrite, komaj opazne vzorce oziroma povezave med izdelki (ki jih človek ni zmožen določiti intuitivno) – kar mu omogoča prav odkrivanje znanja v podatkih.

4.7.2 Uporaba podatkovnega rudarjenja v podjetjih: prednosti in omejitve

Vpeljava podatkovnega rudarjenja v podjetje je precej zahtevna in dolgotrajna naloga. Spodaj naštevam poglavitne prednosti ter omejitve/dejavnike, ki vplivajo na nakup orodja za podatkovno rudarjenje. Prednosti in omejitve so podane na osnovi pregleda literature in lastnih delovnih izkušenj (kot zaposlena v podjetju Crativ Media d.o.o, kjer smo tržili programsko orodje FastStats; kot zaposlena v podjetju Engrotuš d.d., kjer sem sodelovala pri izbiri programskega orodja za podatkovno rudarjenje in pri sami uveljavitvi orodja v podjetju – SAS Enterprise Miner; kot zaposlena v podjetju Studia Moderna d.o.o., kjer orodja za

³¹ Primer: dobavitelj ponudi artikel A v akcijo, trgovec želi po redni ceni pospešit prodajo artikla B. Predlog aktivnosti: poišči vse kupce, ki kupujejo artikel A in ne kupujejo artikla B → ponudi kupon, kjer ob nakupu artikla B, dobijo popust na artikel A.

podatkovno rudarjenje še nimamo in se soočamo s standardnimi omejitvami in pomisleki značilnimi za poslovni sektor (več o tem na straneh 59–60).

Prednosti

Prednosti procesa podatkovnega rudarjenja:

- Ureditev podatkov (dobro organizirano podatkovno skladišče, standardizacija podatkov, podatki se strukturirajo, podatki se očistijo ...).
- Poenotenje obdelave poslovnih dogodkov (vsi podatki o poslovanju so zbrani na enem mestu).
- Omogoča pridobitev novega znanja, ki je uporabno za sprejemanje pravih poslovnih odločitev.
- Uveljavitev podatkovno podprtega trženja (angl. »*database marketing*«), ki omogoča (Weinstein 1994; Pitta 1998; McCorkell 1999; Abbott in drugi 2001; Kotler 2004; Hughes 2006; Kumar in Reinartz 2006; Seng in Chen 2010; Jentzsch in drugi 2013; Khodakarami in Chan 2014; Ho in drugi 2015): opredeljevanje možnih kupcev (kdo se bo odzval na določeno ponudbo/storitev, na določen komunikacijski kanal); izbiranje vrste ponudbe za določeno vrsto kupcev; izbiro načina ponudbe, da kupec ponovno kupi izdelek/storitev; poglobljanje kupčeve zvestobe; predvideti kupčevo nakupno obnašanje (napovedni modeli); razvrščanje in segmentacija kupcev (npr.: po RFM vrednostih, življenjskem ciklu, potrošnji, po nakupnih navadah, po stopnji zvestobe ...).
- Analizo ogromnih količin podatkov (angl. »*Big data analytics*«) na nivoju posameznega objekta (Riggins in Wamba 2015).
- Poleg analiziranja preteklih podatkov, omogoča tudi napovedovanje prihodnjih dogodkov (npr. verjetnost za izgubo kupca v določenem časovnem obdobju).
- Konkurenčna prednost podjetja: znanje pridobljeno skozi KDD proces omogoča trgovcu povečevanje zadovoljstva in zvestobe kupcev (posledično povečanje prodaje: povečamo lahko prodano količino izdelkov; izboljšamo kvaliteto izdelkov in ponudbo prilagodimo posameznim segmentom kupcev; nadgradimo ciljano trženje; povečamo lahko cene izdelkov; kupcu ponudimo komplementarne izdelke/storitve ...) ter predstavlja pomembno konkurenčno prednost pred trgovci, ki tega znanja nimajo.

- Strokovni razvoj zaposlenih: uvedba orodja za podatkovno rudarjenje pomeni za zaposlene dodatna izobraževanja in dodatne izzive.

Omejitve

Omejitve podatkovnega rudarjenja, ki izhajajo iz podatkov:

- Trenutna podatkovna struktura ni primerna za orodje (podjetje še nima zgrajenega podatkovnega skladišča; podjetje še nima zgrajenega analitičnega podatkovnega skladišča oziroma tabel, ki bi bile pripeljane na nivo objekta). Npr. pri trgovcu za primer programa zvestobe, kadar nimamo podatkov o članih programa zvestobe agregiranih po pomembnih atributih (npr. skupno število nakupov, skupna vrednost nakupov, vrednost nakupov po posameznih kategorijah izdelkov ...) po časovni komponenti (teden, mesec, leto).
- Prevelika količina podatkov, ki med seboj niso konsistentni (za iste podatke, se uporabljajo različni termini, različna definicija ...). Gre torej za pomanjkanje standardizacije in za nekompatibilnost obstoječih baz podatkov znotraj posameznega poslovnega procesa.
- Sistemska nepopolnost podatkov.
- Pomanjkanje dokumentacije o arhitekturi podatkovnih baz.
- Vse spremembe na bazi se delajo na produkcijskem okolju (visoka nevarnost napak in izpada baze).
- Problem zmogljivosti osveževanja podatkov.
- V podjetju ni pregleda nad vsemi podatki. Nekateri oddelki ne posredujejo podatkov.
- Zelo pomembni podatki se še vedno zbirajo v excelih (anketni podatki, podatki o stroških, podatki o konkurenci ...), nad katerimi ni centralnega pregleda.
- Problem podvojenih zapisov in podvajanja podatkov.
- Problem manjkajočih zapisov – nekateri pomembni podatki se ne zbirajo konsistentno.
- Tehnične omejitve povezovanja podatkov.
- Težave z razumevanjem lastnih podatkov.
- Pravne omejitve – nekaterih podatkov ne smemo uporabljati zaradi pravnih omejitev.
- Ni jasno določenih poslovnih skrbnikov za posamezne dimenzije podatkov.

Omejitve, ki izhajajo iz vizije in organizacije podjetja:

- Slaba vizija ali celo pomanjkanje vizije.
- Odpor služb, ki v podjetju skrbijo za analizo podatkov (in za dostop do podatkov), v smislu »Povejte nam kaj rabite in vam bomo posredovali, analizirali ...«. Gre za nekakšen strah pred spremembami (ki bi jih vpeljava orodja povzročila) ter strah pred tem, da bi poslovni uporabniki (torej ne informatiki) sami dostopali do podatkov.
- Neskladja med oddelki. Nekateri oddelki ne vidijo dodane vrednosti ob uveljavitvi orodja za podatkovno rudarjenje. Kadar so v teh oddelkih močne in vplivne osebe, lahko zavirajo sam proces.
- Sklicevanje na stroške: visoki stroški vpeljave orodja za podatkovno rudarjenje. Sklicevanje na recesijo: trenutno ni čas za investicijo v tehnologijo, prioriteto imajo investicije za »higienike«, npr. za zagotavljanje plač.
- Zelo težko je izračunati povrnitev investicije, kadar večina pozitivnih posledic ni merljivih.

Povzetek

Da povzamem – proces podatkovnega rudarjenja je v podjetju učinkovit, ko so izpolnjeni naslednji osnovni pogoji, in sicer:

- ko je podatkovno rudarjenje del strategije podjetja ter ima visoko podporo vodstva;
- ko je proces podatkovnega rudarjenja organsko vključen v vse poslovne procese podjetja in se pridobljeno znanje tudi dejansko uporablja (zaloga, planiranje, logistika, prodaja, trženje, razvoj novih izdelkov ...);
- ko se pridobljeno znanje konstruktivno uporablja v namene boljšega razumevanja porabnikov (strank, kupcev), izdelkov, trga in konkurence;
- ko ima podjetje zagotovljen lasten notranji razvoj – strokovne ljudi, ki so vključeni v proces podatkovnega rudarjenja (programski analitiki – IT strokovnjaki ter poslovni uporabniki).

4.8 Primeri raziskav (iz poslovnega okolja) v slovenskem prostoru

Študija analize slovenskega medijskega prostora

Kot primer učenja povezovalnih in klasifikacijskih pravil je prototipna študija analize slovenskega medijskega prostora (Grobelnik in drugi 2003, 133–141). Raziskava je del Evropskega projekta Sol-Eu-Net (v sklopu petega okvirnega programa: »Data mining and decision support for business competitiveness, 2000–2002). Komercialni cilj projekta je ustanovitev virtualnega podjetja za komercializacijo ekspertnih znanj na področju analize podatkov in odločanja (odkrivanje zakonitosti v podatkih, izdelava uporabniških aplikacij, konzultacije ...).

Študija temelji na analizi podatkov o **branosti, gledanosti in poslušnosti** slovenskih medijev (krajše BGP: raziskava Inštituta za raziskovanje trga in medijev, Mediana d.o.o.; raziskava se je izvajala med letoma 1992 in 2002; namen raziskave je definirati slovensko medijsko strategijo in pridobiti sliko seznanjenosti z medijsko podobo v Sloveniji), na podatkih iz leta 1998 (na vzorcu približno 8000 anket ter približno 1200 anketnih vprašanj, ki pokrivajo področja o osebnih interesih, preživljanju prostega časa, demografije ter relacije respondentov do vseh pomembnih slovenskih medijev).

Cilj študije je odkriti še neznane relacije med posameznimi mediji ter odkriti podskupine ljudi s podobnimi interesi:

- Katere tiskane medije berejo bralci posameznega časnika/revije?
- Kakšne so lastnosti bralcev/gledalcev/poslušalcev določenega medija?
- Katere lastnosti ločijo bralce različnih časnikov?

Za odgovor na zastavljena vprašanja so uporabili več tehnik podatkovnega rudarjenja. Zaradi velikega števila atributov so najprej poiskali skupine atributov, ki visoko kolerirajo med seboj (koeficient korelacije $> 0,5$). Tako so dobili boljše razumevanje same strukture anketnega vprašalnika. Nato so uporabili tehniko povezovalnih pravil (algoritem APriori), s katero so odkrili več zanimivih povezav med bralnimi navadami respondentov, ki berejo več kot en časnik/revijo (npr. večina bralcev t.i. rumenega tiska, ki pokriva predvsem ljubezenska in erotična področja: »Sara«, »Ljubezenske zgodbe«, »Dolenjski list«, »Omama«, »Delavska

enotnost«, bere tudi »Slovenske novice«). S tehnikami odločitvenih dreves (algoritem C4.5) so zgradili profil bralcev določenega časopisa/revije (npr. tipičen bralec Slovenskih novic rad poseduje v lokalih, kavarnah in slaščičarnah ...). Na koncu so uporabili tehniko razvrščanja v skupine (algoritem K-means), s katero so respondente razdelili v štiri skupine (»mladi polni zagona«, »neaktivni starejši«, »ambiciozneži«, »aktivni starejši«), ki so si med seboj podobne glede na osebne interese in življenjski slog. Za izdelavo profila posamezne skupine so uporabili tehniko odločitvenih dreves (algoritem C5).

Avtorji (Grobelnik in drugi 2003, 141) navajajo, kot eno izmed značilnosti te študije, da je bilo zelo težko (s poslovnega vidika) upravičiti uporabo metod podatkovnega rudarjenja, v kontekstu povrnitve investicije, do končnega poslovnega uporabnika.

Povečanje vrednosti anketnih podatkov iz raziskave zadovoljstva kupcev v okviru programa zvestobe: primer na slovenskem trgovcu

Kot primer odkrivanja znanja iz anketnih podatkov članov programa zvestobe (program zvestobe »Pika kartica« trgovca Mercator d.d.) služi študija »Povečanje vrednosti anketnih podatkov iz raziskave zadovoljstva kupcev v okviru programa zvestobe: primer na slovenskem trgovcu« (Ograjenšek in Žabkar 2010, 133–147). Cilj študije je razvrstiti kupce v segmente (na osnovi anketnih podatkov: ocenjevanje kakovosti storitev, ki se nanašajo na prodajno osebje – s faktorsko analizo so identificirane tri dimenzije: videz, vzbujanje zaupanja in odzivnost) in zgraditi profil posameznih segmentov (na osnovi demografskih, socioekonomskih in transakcijskih podatkov³²).

Analiza je izvedena na 201 članih programa zvestobe (vzorčenje: slučajen stratificiran vzorec 600 kupcev iz baze programa zvestobe trgovca; naknadno izločenih 36 objektov za katere ni podatka o telefonski številki; 39,7 % odziv na telefonsko anketo; ostane 201 respondentov), le-te so razvrstili v tri segmente na osnovi kombinacije hierarhičnih (za določitev števila skupin: Ward-ov algoritem) in ne-hierarhičnih (končno razvrščanje) metod razvrščanja v skupine. Profili segmentov so zgrajeni na osnovi primerjave demografskih in vedenjskih

³² Tukaj ne gre za analizo posameznih transakcij na nivoju pozicije (oziroma na nivoju artiklov), temveč za vedenjske podatke, ki so jih pridobili iz transakcij na nivoju računa: skupna potrošnja v obdobju šestih mesecev s plačilno kartico »Pika«, število obiskanih poslovnih enot trgovca v obdobju šestih mesecev, maksimalno število nakupov s kartico programa zvestobe v eni trgovini v obdobju šestih mesecev, skupno število vseh nakupov v trgovinah v obdobju šestih mesecev.

(transakcijskih) atributov med segmenti (Pearsonov Hi-kvadrat test, F-vrednost, osnovne opisne statistike). Na koncu študije so iz rezultatov analize podana priporočila vodstvu podjetja, v obliki izzivov za nadaljnja raziskovanja.

Analiza segmentov na bančnem trgu občanov – primer na Sloveniji

Kot primer razvrščanja, je študija »Analiza segmentov na bančnem trgu občanov« (Horvat in drugi 1998). Osnovni namen analize podatkov je razvrstiti občane na slovenskem bančnem trgu v segmente oziroma skupine tako, da so si občani znotraj posameznega segmenta med seboj čim bolj podobni, med segmenti pa čim bolj različni (na osnovi uporabe bančnih storitev, demografskih podatkov ter odnosa med občani in bankami; anketni vprašalnik; slučajni vzorec velikosti 2809; vir podatkov – marketinška agencija »PR plus RM«, obdobje zbiranja podatkov: maj–junij 1997). Za razvrščanje so uporabili metodo hierarhičnega združevanja objektov (občanov) v skupine. Za izdelavo profila (oziroma izdelavo značilnosti) posameznega segmenta so uporabili multiplo korespondenčno analizo (angl. »*multiple correspondence analysis*«). Slovenski bančni trg občanov so razdelili v sedem različnih segmentov. Poznavanje profilov posameznih segmentov slovenskim bankam omogoča poznavanje lastnosti in vedenja komitentov, to znanje jim lahko omogoča sprejemanje boljših odločitev, predvsem v domeni ciljanega trženja (npr. izbiranje vrste bančne storitve za določen segment komitentov).

Poznavanje blagovnih znamk in etnocentrizem porabnikov kot dejavnika nakupnega obnašanja

Namen študije »Poznavanje blagovnih znamk in etnocentrizem³³ porabnikov kot dejavnika nakupnega obnašanja« (Damjan in Vida 1997, 21–28; Vida in drugi 2015), je poglobljeno razumevanje vloge etnocentrizma pri nakupnem obnašanju porabnikov (natančneje kupcev) skozi preučevanje dveh dejavnikov, ki vplivata na odločitev kupcev za domačo ali tujo blagovno znamko:

- težnja kupcev k etnocentrizmu ter
- poznavanje blagovnih znamk, kot možnega antecedenta etnocentrizma kupcev.

³³ Prepričanje, da je kupovanje uvoženih izdelkov napačno, saj škodi domačemu prebivalstvu, povzroča brezposelnost in je moralno napačno – takšni izdelki pa so lahko predmet zavračanja oziroma nekupovanja (Shimp in Sharma v Damjan in Vida 1997, 22).

Podatke so analizirali na vzorcu 86 študentov tretjega letnika Ekonomske fakultete (leta 1995; anketni vprašalnik: usmerjenost k etnocentrizmu kupcev, poznavanje blagovnih znamk, podatki o dejanskem nakupu in izvoru desetih izdelkov, demografski podatki). Za razumevanje podatkov so uporabili osnovne opisne statistike, za odgovor na raziskovalna vprašanja pa Pearsonov koeficient korelacije, analizo variance in multiplo regresijsko analizo. Kljub temu da namen same študije ni analiza podatkov s tehnikami podatkovnega rudarjenja, pa to študijo obravnavam kot relevantno za obravnavano problematiko magistrskega dela, saj gre za odkrivanje novega in uporabnega znanja na področju nakupnega obnašanja kupcev, pri čemer to znanje lahko (ob uporabi v praksi) dejansko prispeva k povečevanju zvestobe kupcev. Primer: če bi trgovec za vsakega člana programa zvestobe razpolagal z oceno stopnje etnocentrizma, bi lahko to znanje uporabil pri ciljanem trženju, tako da bi kupcem z visoko stopnjo etnocentrizma poslal posebno ponudbo z domačimi oziroma slovenskimi artikli, kupcem z nizko stopnjo pa mednarodne oziroma tuje artikle.

Povzetek

Novo in uporabno znanje je potrebno za kvalitetno vodenje vsakega podjetja (trgovci niso tu nikakršna izjema), za doseganje zadovoljstva in zvestobe porabnikov, za ustvarjanje dobičkonosnosti, za ustvarjanje konkurenčne prednosti pred podjetji, ki tega znanja bodisi nimajo ali pa ga imajo, vendar ga ne znajo uporabiti. Zelo pomembno je znanje o lastnih porabnikih, kjer je pomembno, da v proces odkrivanja znanja iz podatkov, zajamemo tako notranje kot zunanje zbrane podatke. Od analize transakcijskih podatkov, dodatno zbranih podatkov znotraj podjetja (preko različnih papirnih formularjev: pristopnica za program zadovoljstva, nagradne igre za zbiranje dodatnih podatkov o uporabnikih, anketni vprašalniki za merjenje zadovoljstva itd.; podatki zbrani znotraj oddelka za reševanje reklamacij; podatki zbrani znotraj klicnega centra; podatki zbrani od zaposlenih, ki so v stalnem stiku s porabniki; podatki iz knjige pohval in predlogov kupcev; podatki zbranimi preko interneta in socialnih omrežij ...) ter zunanje zbranih podatkov (tržne raziskave, zunanje raziskave zadovoljstva, podatki iz statističnega urada ...).

Pri analizi ogromne količine zbranih podatkov so podjetju v veliko pomoč orodja za podatkovno rudarjenje.

5 EKSPERIMENTI IN REZULTATI

»Vsi si prizadevajo, da bi osvojili to, česar ne vedo.
Nihče pa si ne prizadeva, da bi osvojil to, kar že ve.«

Čuang Ce

Namen empiričnega dela magistrske naloge je predstaviti uporabo podatkovnega rudarjenja na primeru trgovca Engrotuš d.d. za povečevanje zvestobe članov programa zvestobe Tuš kluba. Za analizo podatkov sem uporabila orodje IBM SPSS MODELER 17.0 ter sledila CRISP-DM metodologiji, ki mi je pomagala pri samih postopkih priprave in izvedbe podatkovnega rudarjenja. V pričujočem poglavju podam opis podatkov, kratek oris procesa priprave podatkov, pregled rezultatov ter poglavje zaključim s konkretnim modelom uporabe procesa odkrivanja znanja v podjetju Engrotuš d.d. za povečevanje zvestobe kupcev. Ključna omejitev pri razkrivanju in interpretaciji rezultatov izhaja iz realnih podatkov poslovnega okolja trgovca, ki mi zaradi poslovne skrivnosti onemogoča razkriti občutljive informacije.

5.1 Opis raziskovalnega problema

Ključno raziskovalno vprašanje, ki ga bom reševala v empiričnem delu magistrskega dela je, kako ogromno količino zbranih podatkov iz okvira programa zvestobe (o kupcih in zgodovini njihovih nakupov) obvladati in učinkovito pretvoriti v uporabno znanje za povečevanje zvestobe kupcev. Na voljo imam dve skupini podatkov:

1. transakcijski podatki (podatki na računu: čas nakupa, kraj nakupa, kupljeni izdelki, cena izdelkov ...) in
2. demografski podatki (spol, starost, kraj bivanja, regija bivanja, izobrazba ...).

Vir podatkov so torej relacijske podatkovne baze, ki so last podjetja Engrotuš d.d. in niso javno dostopna. Zaradi občutljivosti podatkov je vzorec določil lastnik – slučajni vzorec 7000 članov programa zvestobe Tuš kluba, z vsemi njihovimi nakupi znotraj skupine Engrotuš d.d. (brez podatkov o mobilni telefoniji) za obdobje 12 mesecev (avgust 2012–julij 2013).

5.1.1 Odkrivanje znanja v okviru programa zvestobe »Tuš klub«

Podjetje Engrotuš d.d. (v nadaljevanju krajše Tuš) je tretji največji slovenski trgovec³⁴ – mreža poslovnih enot se razpreda po vsej Sloveniji. Dejavnosti trgovca segajo na področja:

- TUŠ TRGOVIN (supermarketi, marketi, franšize Tuš, Cash&Carry trgovine),
- TUŠ DROGERIJ (specializirane Tuš drogerije),
- TUŠ GOSTINSTVA (raznolika gostinska ponudba s cateringom) ter
- TUŠ ZABAVE (bowling in biljard centri, otroški igralni kotički Oslarija),

pri čemer je osnovna dejavnost trgovina.

Tuš (Engrotuš) postavlja kupca v središče svojega delovanja. Poslanstvo uresničujejo na podlagi temeljev s katerimi so si začrtali svojo poslovno pot:

- spoštujmo kupce (odličnost storitve, svežina in kakovost ponudbe, graditev zaupanja do kupca),
- spoštujmo okolje, ki nas obdaja (ključni sestavni del ponudbe so lokalni produkti s čimer dajejo priložnost domačim dobaviteljem; zaupanje v domače in lokalno okolje – slogan »spoštujemo slovensko«) ter
- spoštujmo naše sodelavce (zaposleni so ključ uspeha; omogočanje stabilnega delovnega okolja in osebne rasti).

Pri zaposlenih spodbuja odzivnost, pozitivnost in posluh za kupca, kar se tudi odraža v njihovi **viziji lokalnega trgovca najbolj zadovoljnih in zvestih kupcev** (Engrotuš), ki jo uresničuje skozi program zvestobe Tuš kluba.

Tuš že od leta 2003, z uvedbo Tuš klub kartice³⁵ (podpis prve kartice 29.5.2002) – torej programa zvestobe – zbira in hrani demografske in transakcijske podatke o svojih Tuš klub članih (v nadaljevanju krajše TK člani). Podatki so se vse do leta 2008 le zbirali in hranili, vendar se niso uporabljali za podporo trženju, za povečevanje zvestobe TK članov, kakor tudi ne za podporo poslovnim odločitvam. Od leta 2008 je splošno sprejeto zavedanje, da so

³⁴ Prva trgovina se je odprla leta 1989 v Slovenskih Konjicah (Mlakar 2008, 13). Pod okriljem Tuša danes (v začetku leta 2016) posluje 176 lastnih in franšiznih maloprodajnih trgovin, 40 Tuš drogerij, 6 trgovin na debelo »Cash&Carry«, 3 slaščičarne »De la Creme« ter 5 Planetov Tuš, ki uspešno združujejo trgovino in zabavo v celovito rešitev sodobne trgovske ponudbe (združitev nakupovanja, druženja, zabave, rekreacije in oddiha za vse generacije).

³⁵ V nadaljevanju krajše kartica.

podatki o TK članih izjemno pomembni in so konkurenčna prednost Tuša. Primarni cilj programa zvestobe Tuš kluba je izboljšati (povečati) zvestobo TK članov preko personaliziranega stika s kupcem (primarno orodje je direktna pošta, elektronska pošta, SMS, mobilna aplikacija) ter oblikovanjem ponudb po meri vsakega kupca (lokalno, kakovostno ter cenovno ugodno) – kot del dolgoročne strategije dobičkonosnega obdržanja kupcev.

Članstvo v programu zvestobe je prostovoljno in brezplačno. V Tuš klub se je možno včlaniti v kateri koli poslovni enoti Tuša z izpolnitvijo pristopnega obrazca, ki se ga odda blagajničarki. Začasno kartico, ki se jo izreže iz pristopnega obrazca, lahko novi član začne uporabljati takoj, medtem ko trajno kartico prejme na osebni naslov v roku dveh mesecev. Danes je Tuš klub program zvestobe številnih ugodnosti³⁶ in bonitet iz pestre ponudbe znotraj celotne skupine Tuš (trgovin, drogerij, zabave, gostinstva).

5.2 Opis in razumevanje podatkov

Za razumevanje podatkov je potrebno razumeti, da se vse transakcije oziroma vsi opravljeni nakupi zapisujejo na kartico, pri čemer ima lahko en TK član več kartic³⁷ (najpogosteje je razlog izguba kartice ali identificiranje podvojenih TK članov³⁸). Vsi nakupi iz kartic se tako seštevajo na tako imenovan »Tuš klub račun« (v nadaljevanju krajše TK račun) oziroma enoznačno identifikacijsko številko člana programa zvestobe Tuš klub. Demografski podatki so zapisani na TK računu.

Za izdelek se v Tušu uporablja izraz artikel, zato bom tudi sama v empiričnem delu uporabljala ta izraz. Nekateri artikli imajo več EAN kod, ki se nato združujejo na ARTIKEL (enoznačna identifikacijska številka artikla).

Za posamezno trgovino ali drogerijo se uporablja izraz poslovna enota.

³⁶ D*NAR, popusti, nagrade, takojšnji prihranek, zvezdice zvestobe, akcija Mojih 10 najljubših, cenejše gorivo na vseh bencinskih servisih MOL po Sloveniji, dodatni popusti s kuponi, seniorske srede (11 % D*NAR), dijaški ter študentski torki (10 % D*NAR), ugodnosti pri partnerjih (na področju zdravja, lepote, wellnesa in nege, oddihov, rekreacije, izobraževanj, prireditvev ...).

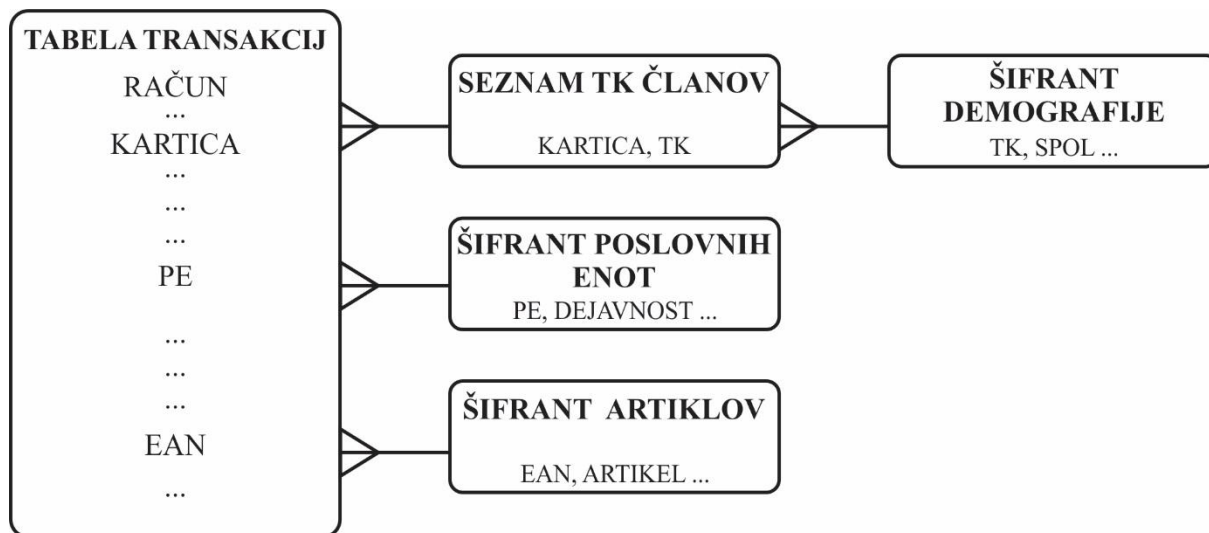
³⁷ Da ima večina TK članov več kot eno kartico se vidi tudi iz slike 5.2 (glej stran 72).

³⁸ Vsaj enkrat na leto analitika izvede proces identifikacije duplikatov oziroma podvojenih TK računov (na osnovi demografskih podatkov). Vse kartice se tako prenesejo na glavni TK račun (TK račun, ki je bil nazadnje kreiran).

5.2.1 Podatkovni model

Na spodnji sliki (glej sliko 5.1) je prikazana struktura podatkovnega modela za potrebe magistrskega dela.

Slika 5.1: Struktura podatkovnega modela za potrebe magistrskega dela.



Podatkovni model vsebuje:

- Transakcijske podatke oziroma podatke o nakupnih košaricah: kupljeni artikli, količina, čas nakupa, poslovna enota nakupa, maloprodajna cena izdelka, popust ... (pred pripravo podatkov: 31 atributov, 4965998 enot; po končanem procesu priprave podatkov: 11 atributov, 4965498 enot).
- Podatke o poslovnih enotah: naziv poslovne enote, kraj, kontaktni podatki, poslovodja, dejavnost poslovne enote ... (pred pripravo podatkov: 23 atributov, 604 enot; po končanem procesu priprave podatkov: 11 atributov, 234 enot).
- Podatke o artiklih: šifre artiklov in opisi artiklov, ki so v ponudbi Tuš trgovin in drogerij (pred pripravo podatkov: 45 atributov, 118695 enot; po končanem procesu priprave podatkov: 14 atributov, 45004 enot).
- Seznam kartic in TK računov: kartica, TK (pred pripravo podatkov: 2 atributa, 15133 enot; po končanem procesu priprave podatkov; 2 atributa, 15130 enot).
- Podatke o demografskih podatkih TK članov: kontaktni podatki, dovoljenja za kontaktiranje po prodajnih kanalih ... (pred pripravo podatkov: 20 atributov, 7000 enot; po končanem procesu priprave podatkov: 6 atributov, 6997 enot).

5.2.2 Priprava podatkov

Priprava podatkov zajema vse aktivnosti, ki so potrebne, da pripravim končno množico podatkov za vhod v tehnike podatkovnega rudarjenja. V procesu priprave podatkov tako: odstranim attribute, ki jih v analizi ne bom potrebovala ter attribute, ki nimajo informativne vrednosti; odstranim šum (ekstremne vrednosti, attribute z večjo količino manjkajočih vrednosti); preverim, da nimam duplikatov oziroma podvojenih kupcev; obravnavam manjkajoče vrednosti; transformiram določene attribute; izpeljem nove attribute; pregledam osnovne statistike in porazdelitve podatkov; kreiram tabelo in ciljni atribut (angl. »*target variable*«) za vsak posamezen model.

Izbira oziroma filtriranje podatkov: v vsaki posamezni tabeli najprej odstranim vse attribute, ki jih v analizi ne bom potrebovala (npr. odstranim poslovne enote in artikle, ki se ne nahajajo v tabeli transakcij, odstranim TK račune brez kartic). Nato odstranim attribute, ki nimajo informativne vrednosti (npr. kontaktni podatki za poslovalnice, podatki o dobaviteljih ...) ali niso zanesljivi (takšen primer je izobrazba, število družinskih članov in status – vsi ti podatki se vpišejo le na pristopnico in se kasneje ne posodablajo, prav tako je ogromno manjkajočih vrednosti).

Iskanje šuma v podatkih: izločim šum. Izločim vse račune iz dejavnosti TUŠ ZABAVA in TUŠ GOSTINSTVO (0,04 % računov); izločim račune, ki nakazujejo na napake na blagajni (npr. v polje za količino se zapiše EAN koda izdelka, blagajničarka se zatipka – računi z ekstremnimi količinami) ali na zlorabo TK kartice³⁹ (tako skupno izločim dodatnih 0,01 % računov)⁴⁰. Primer šuma v podatkih so tudi stornirani računi, vendar le-te ohranim pri analizi povezovalnih pravil, saj imajo informativno vrednost – kupec je položil artikel v košarico oziroma je nakazal interes za nakup⁴¹. Kljub izredno majhnemu številu storniranih računov (0,7 %), le-te ne upoštevam pri osnovnih statistikah in analizah. Še vedno ostajajo računi, katere ne morem identificirati kot šum⁴² (ocenjujem manj kot 1 % računov), vendar zaradi majhnega števila ne morejo pomembno vplivati na rezultate.

³⁹ Npr. nakup za piknik zaposlenih (npr. 480 kosov »ČEVAPČIČI 480 g PAK.«, 720 pločevink piva ...).

⁴⁰ Vsak izločen račun je ročno pregledan.

⁴¹ Iz prakse je največ takšnih stornacij zato, ker kupec na blagajni ugotovi, da ne more koristiti akcijske cene in zato zavrne nakup.

⁴² V franšiznih prodajalnah se dogaja, da v primeru stornacij blagajničarka ne naredi stornacije računa na TK kartico, temveč na račun brez kartice, t.i. neznanega kupca (nimamo računa z negativno vrednostjo). Ali večji nakupi za katere ne morem z gotovostjo trditi, da gre za zlorabo.

Obravnava manjkajočih vrednosti: na vseh atributih preverim manjkajoče vrednosti. Podatki v transakcijski tabeli in šifrantih poslovnih enot so popolni. V tabeli šifrantov artiklov, so manjkajoče vrednosti na blagovnih skupinah (obrazložitev taksonomije blagovnih skupin podajam v poglavju 5.6 Analiza nakupne košarice), kar 24 % artiklov ni razvrščenih ali so razvrščeni pod »neznano«. V šifrantu demografskih podatkov TK članov so manjkajoče vrednosti na atributih: spol 0,3 %⁴³, starost 12 %⁴⁴ in regija 1,6 %⁴⁵. Medtem ko izobrazbo (33 % manjkajočih vrednosti), število družinskih članov (31 %) ter status (64 %) izločim iz analize.

Transformacija podatkov: podatke transformiram v najprimernejšo obliko za odkrivanje znanja v podatkih, npr. namesto vseh zapisov nekega atributa, uporabim samo njihov seštevek (letni seštevek maloprodajne vrednosti na TK člana, letni seštevek števila nakupov na TK člana ...) ali pa zmanjšam število vrednosti posameznega atributa (npr. starost združim v razrede, ki najbolj ustrezajo poslovnih vsebini⁴⁶).

Izpeljava novih atributov: RAČUN⁴⁷ (enoznačna identifikacijska številka nakupa oziroma nakupne košarice), MP_VREDNOST⁴⁸ (maloprodajna vrednost), številni agregirani atributi na nivoju računa ter na nivoju TK člana (SUM_MP_VRED, N_RACUNOV, N_POZICIJ, N_ARTIKLOV ...) ter ciljna atributa TOP_ZVESTI (segment najbolj zvestih trgovcu) in TOP_LBZ (segment najbolj zvestih lastni trgovski znamki).

Integracija podatkov: vse tabele relacijsko povežem in kreiram novo tabelo (ki jo poimenujem POZICIJE_DELOVNA_TABELA), ki vsebuje 43 atributov ter 4966604 enot. Tabela je osnova za vse nadaljnje analize. Prav tako kreiram novo tabelo, kjer so podatki agregirani na nivoju TK člana (ki jo poimenujem TK_KONČNA), ki vsebuje 23 atributov ter 6997 enot. Za potrebe analize povezovalnih pravil, vhodno transakcijsko tabelo prevedem v binarno obliko primerno za uporabo algoritma APriori, pri čemer je objekt posamezen račun (oziroma nakupna košarica), atributi pa blagovne skupine (vrednosti 1/0; vrednost 1 pomeni, da je

⁴³ Za potrebe modeliranja manjkajoče vrednosti popolnih z vrednostjo modusa.

⁴⁴ TK člane z manjkajočimi vrednostmi grupiram v svoj razred, saj gre za vsebinsko kupce, ki ne želijo deliti osebnih podatkov, v kolikor to ni obvezen podatek za pristop k programu zvestobe.

⁴⁵ Večino (1,5 %) manjkajočih vrednosti popolnih s pravilno regijo glede na atribut poštna številka in država, medtem ko manjšino (0,1 %) slučajno porazdelim v Podravsko, Osrednjeslovensko ali Savinjsko regijo (delež teh treh regij je 57 %).

⁴⁶ Na starostne kategorije, ki so uporabne za aktivnosti ciljanega trženja.

⁴⁷ Trimend (PE >> STEVILKA)

⁴⁸ KOLICINA * MPC * (1 - POPUST/100)

atribut prisoten v nakupni košarici). Predhodno izločim vse račune, ki imajo manj kot dva artikla. Povezovalna pravila gledam samo na računih iz dejavnosti TUŠ TRGOVINE.

5.3 Osnovne statistike in analize

Osnovne statistike na podatkih za obdobje 12 mesecev⁴⁹:

- 6997 TK članov, ki imajo skupno 15130 kartic (v povprečju 2 kartici na TK člana; za porazdelitev kartic glej sliko 5.2 na naslednji strani), je opravilo 495287 nakupov (78 % nakupov v Tuš lastnih trgovinah, 19 % v Tuš franšiznih trgovinah in 3 % v Tuš drogerijah) v 234 poslovalnicah (v Tuš lastnih trgovinah je vsaj en nakup opravilo 94 % TK članov, v Tuš franšiznih trgovinah 36 %, v Tuš drogerijah 42 % ter v vseh treh hkrati 12 %);
- v nakupih je bilo prodanih 45004 različnih izdelkov⁵⁰ (45 % znotraj »5 BLAGOVNE SKUPINE«, 22 % »NEŽIVILA – MARKET PROGRAM«, 20 % »SUHI PROGRAM«, 10 % »SVEŽI PROGRAM«, 2 % »ZAMRZNJENI PROGRAM« ter 1 % »GORIVO« in »EMBALAŽA«, od tega 1120 (2,5 %) znotraj lastne trgovske znamke (1050 »LBZ«⁵¹ ter 70 »OLIMP«⁵²);
- 6 % TK članov opravijo nakup v Tušu skoraj vsak dan; 16 % na vsaj vsaka dva dni; 36 % na vsaj enkrat na pet dni; 51 % vsaj enkrat na teden; 66 % vsaj enkrat na vsakih deset dni ter 97 % vsaj enkrat na mesec – gre za porazdelitev⁵³ (glej sliko 5.3 na naslednji strani), ki je pričakovana in značilna za takšne pojave;
- v povprečju TK član nakupuje v treh poslovalnicah⁵⁴;
- v obdobju 12 mesecev TK član v povprečju nakupuje 235 različnih artiklov⁵⁵ – porazdelitev števila artiklov prikazujem v spodnji sliki (glej sliko 5.4 na naslednji strani).

⁴⁹ Podatkov o skupni potrošnji v obdobju 12 mesecev, o povprečni vrednosti nakupne košarice, o vrednosti popustov itd., ne navajam zaradi občutljivosti podatkov.

⁵⁰ 53054 EAN kod.

⁵¹ LBZ = lastna blagovna znamka trgovca Tuš, ki je višje kakovosti.

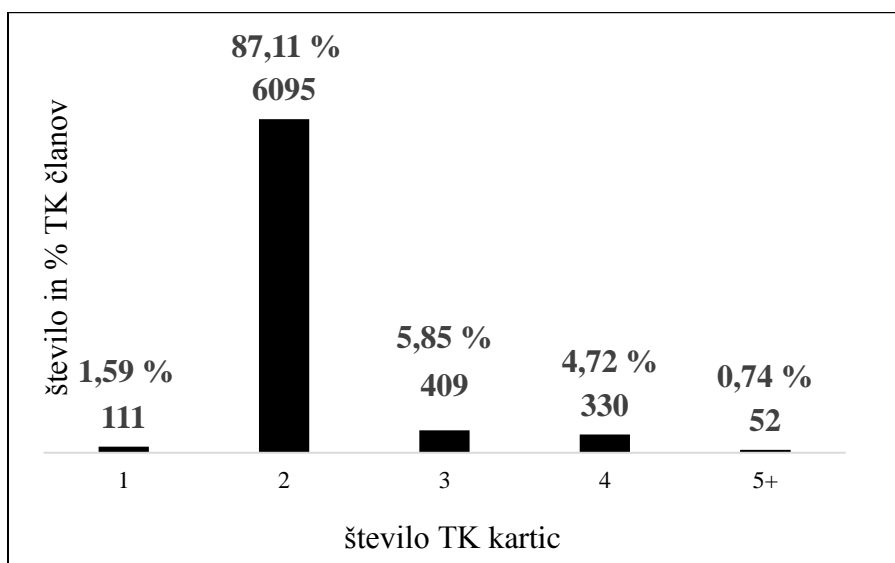
⁵² OLIMP = lastna blagovna znamka trgovca Tuš, ki je nižje kakovosti.

⁵³ Aritmetična sredina = 71,297 (standardni odklon 60,694), mediana = 50.

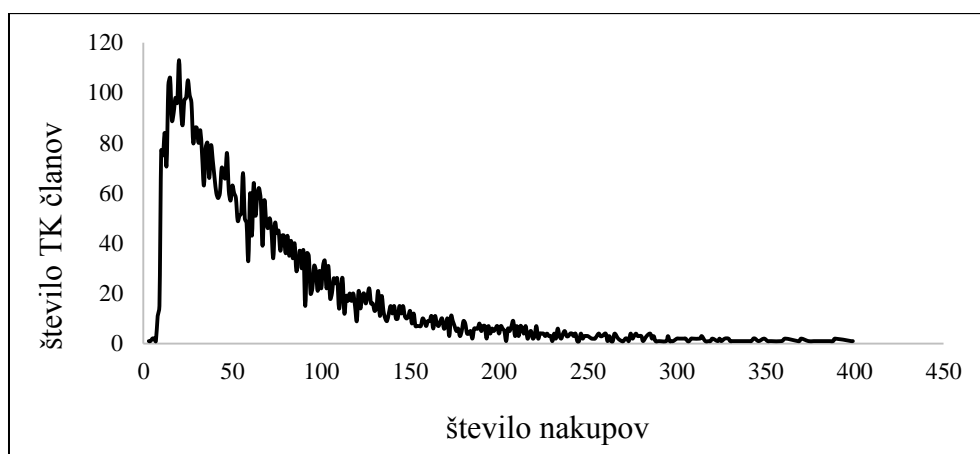
⁵⁴ Aritmetična sredina = 3,331 (standardni odklon 2,132), mediana = 3.

⁵⁵ Aritmetična sredina = 274,974 (standardni odklon 177,115), mediana = 235;

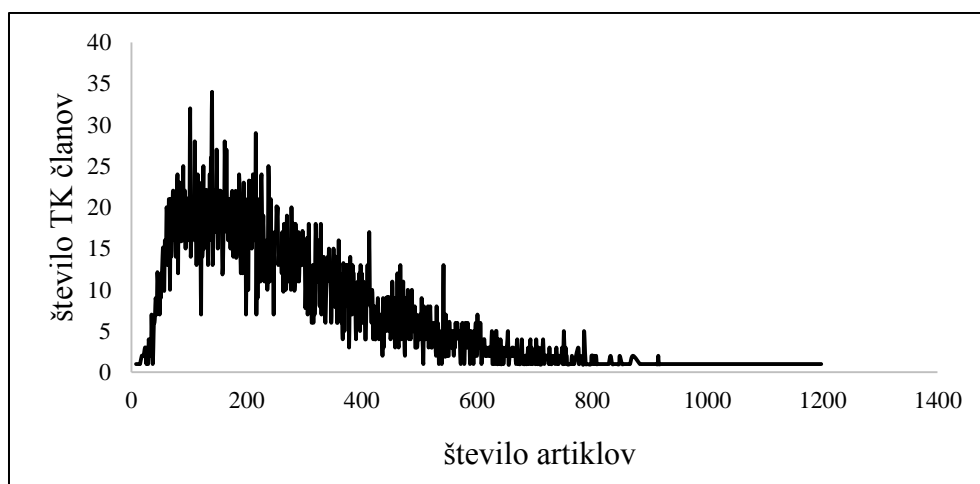
Slika 5.2: Porazdelitev TK kartic na TK člane.



Slika 5.3: Porazdelitev števila nakupov na TK člana za obdobje 12 mesecev.



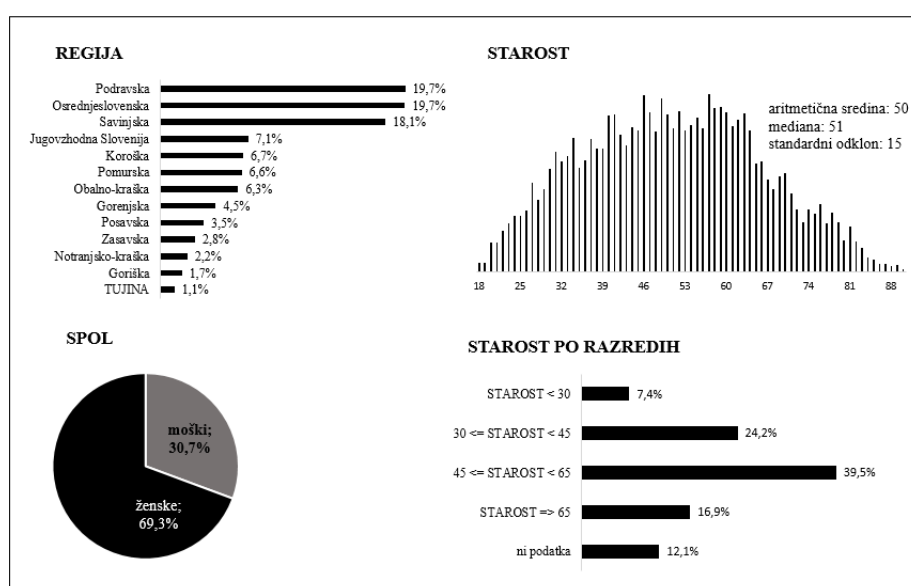
Slika 5.4: Porazdelitev števila artiklov na TK člana za obdobje 12 mesecev.



5.4 Opis vzorca


Opis vzorca⁵⁶ po demografskih značilnostih je prikazan na sliki 5.5. Povprečna starost TK člana je 50 let, 7 % jih je mlajših od 30 let ter 17 % starejših od 65 let. Za 12 % ni podatka o starosti – gre za TK člane, ki ne želijo deliti osebnih podatkov, ki niso obvezni za pristop k programu zvestobe. Več kot polovica (58 %) jih je iz Podravske, Osrednjeslovenske ali Savinjske regije, ter zelo majhen delež (1 %) ima bivališče izven Slovenije. Po spolu je 69 % žensk in 31 % moških.

Slika 5.5: Vzorec 6977 TK članov po demografskih značilnostih.



Večina (98 %) TK članov dovoljuje kontaktiranje preko direktne pošte, tretjina (31 %) preko SMS-ov in le šestina (15 %) preko elektronske pošte (glej sliko 5.6).

Slika 5.6: Vzorec 6977 TK članov po dovoljenjih za kontaktiranje.



⁵⁶ Populacija TK članov je v letu 2013 štela več kot 540000 članov, vendar zaradi poslovne skrivnosti ne razkrivam demografske strukture oziroma splošnega profila.

5.5 Izgradnja taktičnih segmentov kupcev

Za povečevanje zvestobe kupcev je ključnega pomena, da trgovec zna prepoznati oziroma identificirati najbolj zveste kupce. Pri čemer je pomembno, da loči med kupci, ki so zvesti trgovcu (TOP_ZVESTI oziroma »top zvesti Tuš«) ter kupci, ki so zvesti lastni blagovni znamki trgovca (TOP_LBZ oziroma »top zvesti LBZ«). Kot kriterij za najbolj zveste kupce⁵⁷ sem vzela skupno potrošnjo v obdobju enega leta znotraj skupine Tuš (Tuš trgovine in Tuš drogerije). Najbolj zvesti kupci so tisti, ki skupno ustvarijo 30 % celotne maloprodajne vrednosti oziroma prihodkov: 10,3 % TK članov (TOP_ZVESTI) ustvari 30 % maloprodajne vrednosti znotraj skupine Tuš ter 8,1 % TK članov (TOP_LBZ) ustvari 30 % maloprodajne vrednosti znotraj lastne blagovne znamke trgovca Tuš. Le polovica (52 %) članov iz segmenta TOP_ZVESTI je hkrati tudi v segmentu TOP_LBZ ter dve tretjini (66 %) članov iz segmenta TOP_LBZ je hkrati v segmentu TOP_ZVESTI – kar pomeni, da zvestobo trgovcu v polovici določa zvestoba trgovčevi lastni blagovni znamki, polovico pa določajo drugi dejavniki (demografija, kakovost izdelkov ...).

Nadalje me zanima ali demografske značilnosti (spol, starost, regija) vplivajo na zvestobo trgovcu ter na zvestobo lastni trgovčevi blagovni znamki. Segmentacija ni smiselna, če ne obstajajo statistično značilne razlike med skupinami znotraj segmenta – v konkretnem primeru med skupinama TOP_ZVESTI/LBZ DA ter TOP_ZVESTI/LBZ NE. Razlike med skupinama sem preverjala s Hi-kvadrat testom. Pri obeh taktičnih segmentih ter pri vseh treh atributih, so razlike statistično značilne (za kontingenčne tabele in pripadajoče Hi-kvadrat teste glej PRILOGO B: Profil taktičnih segmentov kupcev). Zaključim torej lahko, da se skupini (DA, NE) pri obeh taktičnih segmentih (TOP_ZVESTI in TOP_LBZ) glede na dane attribute (spol, starost, regija) statistično značilno razlikujeta.

Profil TOP_ZVESTI: TK člani ženskega spola, v starosti 45 do 65 let in nikakor ne mlajši od 30 let ter iz Obalno-kraške, Savinjske in Osrednjeslovenske regije.

⁵⁷ Tukaj kot definicijo za zveste kupce vzamem »TOP kupce«, torej kupce, ki trgovcu prinašajo največ maloprodajne vrednosti. Percepcije kupca do trgovca ne morem meriti (nimam podatkov), povprečna frekvenca nakupov znotraj TOP_ZVESTI (3 krat tedensko) je bistveno višja kot med celotnim vzorcem (1 krat tedensko), torej lahko zaključim, da so v povprečju to zvesti kupci tudi po frekvenci. V samih pogojih za definicijo »TOP ZVESTI«, se ne omejujem na frekvenco, zato, da ohranjam vsebinsko enostavnost segmenta in s tem povečujem možnost implementacije segmenta v poslovnem okolju.

Profil TOP_LBZ: TK člani ženskega spola, v starosti 45 do 65 let ter iz Koroške in Obalno-kraške regije.

Profila obeh taktičnih segmentov sta si torej dokaj podobna, z razliko, da je v TOP_LBZ-ju nekoliko več moških (TOP_LBZ 25,7 %; TOP_ZVESTI 23,67 %), več mlajših oziroma pod 30 let (TOP_LBZ 3,3 %; TOP_ZVESTI 2,9 %) ter več iz Koroške regije (TOP_LBZ 11,1 %; TOP_ZVESTI 7,5 %). To je zelo vzpodbudna in uporabna informacija za trgovca Tuš pri oblikovanju strategije lastne blagovne znamke, pri trženjskih aktivnostih za pospeševanje prodaje in informiranja kupcev o lastni blagovni znamki ter za gradnjo in pospeševanje zvestobe lastni blagovni znamki in trgovini oziroma skupini Tuš – pri populaciji, kjer trenutno Tuš ni najbolj močan. Zaključim lahko, da ima Tuš velik potencial povečevanja zvestobe kupcev skupini Tuš s povečanjem naporov pri gradnji strategije in zvestobe lastne blagovne znamke.

Oba profila se tudi kar precej razlikujeta od profila splošnega kupca, glede na splošno populacijo 18 do 100 let (SURs, za leto 2013):

- SPOL: glede na splošno populacijo je večji delež kupcev ženskega spola (splošna populacija 51 %; TOP_ZVESTI 76 %; TOP_LBZ 74 %).
- STAROST: glede na splošno populacijo je večji delež kupcev v starosti 45 let in več (splošna populacija 56 %; TOP_ZVESTI 63 %; TOP_LBZ 63 %).
- REGIJA: glede na splošno populacijo je večji delež kupcev iz Savinjske regije (splošna populacija 13 %; TOP_ZVESTI 19 %; TOP_LBZ 18 %), Podravske regije (splošna populacija 16 %; TOP_ZVESTI 19 %; TOP_LBZ 20 %), Koroške regije (splošna populacija 4 %; TOP_ZVESTI 7 %; TOP_LBZ 11 %) ter Obalno-kraške regije (splošna populacija 6 %; TOP_ZVESTI 7 %; TOP_LBZ 10 %).

5.5.1 Povezava segmentov s statističnimi kazalniki po regijah

Analizo nadgradim s povezavo s statističnimi kazalniki (SURs) po regijah (kot obdobje vzamem leto 2013, da so podatki časovno primerljivi). Iz tabele 5.1 (na naslednji strani) je razvidno, da ima Tuš največji delež kupcev (preračunano glede na število prebivalstva v starosti 18 let in več) v Koroški, Savinjski in Zasavski statistični regiji. Gre za regije, kjer je stopnja brezposelnosti visoka, nizek regionalni bruto domači proizvod na prebivalca, nizka

ekonomska rast in majhna površina (z izjemo Savinjske, ki pa ima visoko stopnjo delovne migracije), nizek indeks povprečne mesečne bruto plače, nizek stanovanjski standard. Zelo izstopa Zasavska regija, z visoko gostoto naseljenosti, visokim indeksom feminitete, najvišjim indeksom staranja, najmanjšo stopnjo delovne aktivnosti, z najmanjšo stopnjo ekonomske rasti, z zelo nizkim stanovanjskim standardom, nizkim deležem vključenih otrok v vrtec, visoko kriminaliteto ter z najnižjimi investicijami na prebivalca (za razširjen nabor statističnih kazalnikov glej tabelo B.8 v PRILOGI B). Po deležu med najbolj zvestimi TK člani (skupini Tuš in LBZ) izstopa Obalno-kraška regija, kar je verjetno posledica prisotnosti Planeta Tuš Koper⁵⁸, nakupovalno-zabavnega centra. Pravzaprav gre za lokalno specifičnost. Najmanjši delež TK članov je iz Goriške, Gorenjske in Osrednjeslovenske statistične regije, kjer so zgoraj naštetih kazalnikov med najvišjimi.

Tabela 5.1: Povezava segmentov s statističnimi kazalniki po statističnih regijah.

REGIJA	Celoten vzorec TK članov		TOP ZVESTI TUŠ		TOP ZVESTI LBZ		Stopnja brezposelnosti	Ekonomska rast	Regionalni bruto domači proizvod na prebivalca ⁵⁹	Indeks povprečne mesečne bruto plače
	prebivalstvo 18+		prebivalstvo 18+		prebivalstvo 18+					
	rang	%	rang	%	rang	%				
							2013	2013	2013	2013
Pomurska	6	0,46 %	6	0,05 %	7	0,03 %	17,2	69,5	69,5	87,8
Podravska	4	0,51 %	4	0,05 %	4	0,04 %	14,6	82,4	82,4	91,6
Koroška	1	0,78 %	1	0,09 %	1	0,11 %	13	79,1	79,1	92,3
Savinjska	2	0,59 %	3	0,06 %	2	0,05 %	14	90,2	90,2	91,7
Zasavska	3	0,53 %	5	0,05 %	5	0,04 %	15,9	62,5	62,5	92,9
Posavska	8	0,42 %	10	0,03 %	6	0,03 %	15,7	86,3	86,3	92,9
Jugovzhodna Slovenija	7	0,43 %	7	0,04 %	8	0,03 %	14,3	95	95	99,6
Osrednjeslovenska	10	0,31 %	9	0,03 %	9	0,02 %	11,4	141,6	141,6	110,6
Gorenjska	11	0,19 %	11	0,01 %	11	0,01 %	9,8	85,2	85,2	99
Primorsko-notranjska	9	0,35 %	8	0,03 %	10	0,02 %	12,2	69,7	69,7	87,7
Goriška	12	0,12 %	12	0,01 %	12	0,01 %	11,4	90,4	90,4	95,7
Obalno-kraška	5	0,46 %	2	0,08 %	3	0,04 %	11,7	98,2	98,2	98,1

Vir: Statistični urad Republike Slovenije.

⁵⁸ Otvoritev leta 2010, objekt velikosti 70000 kvadratnih metrov, kjer je na enem mestu združena ponudba nakupovanja, zabave, rekreacije, kulinarike, druženja in preživljanja prostega časa.

⁵⁹ Indeks ravni (Slovenija vsa leta = 100).

Da je trgovec Tuš močan v Savinjski regiji in njeni okolici, gre tudi pripisati dejstvu, da se je prva trgovina odprla v Savinjski regiji (Slovenske Konjice) in da je lastnik Mirko Tuš Celjan. Tako se je Tuš najprej širil predvsem v Savinjski regiji, kjer je tudi kot osebnost dobro prepoznan in spoštovan.

5.5.2 Dodatna obogatitev profila segmentov z vsemi razpoložljivimi podatki

Profil obeh segmentov (TOP_ZVESTI, TOP_LBZ) lahko trgovec Tuš (ali navsezadnje kateri koli trgovec) obogati z vsemi razpoložljivimi podatki, ki jih shranjuje znotraj podatkovnega skladišča. Za ta namen je potrebno kreirati novo tabelo, v kateri se sumira (ali šteje) vrednosti atributov za določeno obdobje (npr. zadnjih 12 mesecev)⁶⁰, na nivoju posameznega objekta (TK člana). Na novo se tako lahko kreira naslednje attribute:

- X VRED_PRO (skupna prodajna vrednost),
- X VRED_RVC (skupna razlika v ceni⁶¹),
- X VRED_POPUST (skupna vrednost popustov),
- X RAČUNOV_N (skupno število nakupov),
- X ARTIKLOV_N (skupno število različnih artiklov),
- X KOLIČINA (skupna količinska vrednost artiklov),
- X VRED_PRO_BS (skupna prodajna vrednost brez popusta),
- X VRED_PRO_SP (skupna prodajna vrednost s popustom),
- X DELEŽ_POPUST_VRED_PRO (delež popusta znotraj prodane vrednosti),
- X DELEŽ_LBZ_VRED_PRO (delež LBZ prodajne vrednosti notraj celotne prodajne vrednosti),
- X DELEŽ_Y_VRED_PRO (delež prodajne vrednosti Y kategorije znotraj celotne prodajne vrednosti, pri čemer je Y lahko: posamezen artikel, posamezna blagovna skupina, posamezna blagovna znamka, posamezen dobavitelj ...).

⁶⁰ Podatki se lahko sumirajo za vsak mesec posebej in se nato naknadno (glede na poslovne potrebe) sumirajo za želeno obdobje, npr. zadnjih 6 mesecev, zadnjih 12 mesecev ...

⁶¹ RVC = prodajna vrednost – nabavna vrednost.

Pri čemer je X:

- X = NAZIV_BS1 (podatke sumiramo po vseh posameznih blagovnih skupinah na najvišjem nivoju blagovnih skupin⁶²),
- X = NAZIV_BS3 (podatke sumiramo po vseh posameznih blagovnih skupinah na srednjem nivoju blagovnih skupin),
- X = NAZIV_BS (podatke sumiramo po vseh posameznih blagovnih skupinah na najnižjem nivoju blagovnih skupin),
- X = NAZIV_ARTIKEL (podatke sumiramo po vseh posameznih artiklih),
- X = LBZ_OLIMP (podatke sumiramo skupaj za vse lastne blagovne znamke trgovca Tuš),
- X = NAZIV_BLZ (podatke sumiramo po vseh posameznih blagovnih znamkah),
- X = NAZIV_DOBAVITEL (podatke sumiramo po vseh posameznih dobaviteljih),
- X = SEGMENT_segment (podatke sumiramo za vse segmentacije s katerimi razpolaga trgovec⁶³ ter po posameznih segmentih),
- X = DAN_dan (podatke sumiramo po vseh posameznih dnevih v tednu: ločeno po vseh posameznih blagovnih skupinah na vseh treh nivojih),
- X = URA_ura (podatke sumiramo po urah nakupa, npr. ure nakupa rangiramo v štiri razrede: 6:00 – 10:00; 11:00 – 14:00; 15:00 – 18:00; 19:00 – 5:00),
- X = TUŠ_DEJAVNOST_dejavnost (podatke sumiramo po dejavnostih Tuš skupine: trgovine, drogerije, restavracije ...),
- X = PE_pe (podatke sumiramo po posameznih poslovalnicah),
- X = PE_tip (podatke sumiramo po tipih poslovalnic: supermarket, velik market, mini market, hipermarket ..., ločeno na franšizne in lastne Tuš trgovine).

Dodatno lahko kreiramo še naslednje attribute:

- PE_RAZLIČNIH_N (število različnih poslovnih enot, v katerih TK član nakupuje),
- PE_RAZLIČNIH_N_tip (število različnih poslovnih enot, v katerih TK član nakupuje, ločeno po tipih poslovnih enot),
- TUŠ_DEJAVNOST_RAZLIČNIH_N (število različnih dejavnosti, v katerih TK član nakupuje),

⁶² Taksonomija blagovnih skupin, kot jo ima zastavljeno Tuš, je obrazložena v nadaljevanju (glej poglavje 5.6 Analiza nakupne košarice).

⁶³ S katerimi segmentacijami razpolaga Tuš je poslovna skrivnost.

- RANG_X_NAKUPOV (število nakupov TK člana znotraj posameznega ranga vrednosti nakupa, npr: 0 € do 10 €; 10 € do 20 €; 20 € do 30 € ...),
- BONITETE_PREJETO_SKUPAJ (skupno število prejetih bonitet⁶⁴),
- BONITETE_PORABLJENO_SKUPAJ (skupno število porabljenih bonitet),
- BONITETE_PREJETO_tip (skupno število prejetih bonitet, ločeno po posameznih tipih bonitet, npr: MOL_CENTI, TUŠ_MOBIL, KUPONI, TOČKE_POTOVANJA, PLANET_TOČKE ...),
- BONITETE_PORABLJENO_tip (skupno število porabljenih bonitet, ločeno po posameznih tipih bonitet),
- MOJIH_10_N (število aktiviranih artiklov znotraj akcije Mojih 10⁶⁵),
- DIREKTNA_POŠTA_N (skupno število prejetih direktnih pošt),
- DIREKTNA_POŠTA_N_tip (skupno število prejetih direktnih pošt glede na tip direktne pošte: informativna, prodajna⁶⁶),
- DIREKTNA_POŠTA_ODZIV_N (skupno število direktnih pošt, na katere se je TK član odzval⁶⁷),
- SMS_N (skupno število prejetih SMS-ov),
- SMS_ODZIV_N (skupno število SMS-ov, na katere se je TK član odzval),
- EMAIL_N (skupno število prejetih elektronskih pošt),
- EMAIL_ODZIV_N (skupno število elektronskih pošt, na katere se je TK član odzval).

Tako lahko kreiramo ogromno število atributov, zato je vsebinsko poznavanje poslovnega problema ključnega pomena. Za potrebe magistrskega dela v tabeli 5.2 (na naslednji strani), nakažem⁶⁸ razlike med profiloma TOP_ZVESTI in TOP_LBZ glede na celoten vzorec TK članov, samo na izboru atributov⁶⁹, ki so tesno povezani z zvestobo (hkrati imajo najbolj uporabno vrednost s poslovnega vidika) ter dodatno podam še nekaj primerov iz bolj podrobne oziroma nižje hierarhije (atributi z manjšo uporabno vrednostjo).

⁶⁴ Bonitete so npr.: gratis Tuš Mobil minute ob nakupu nad določeno vrednostjo, Mol centi pri nakupu nad določeno vrednostjo, gratis 1 liter Mleka ob nakupu nad določeno vrednostjo, kupon za 10 % popust na vrednost celotnega nakupa, planet točke za ugodnosti v Tuš kinematografih, točke za ugotnosti pri potovalni agenciji Sonček ...).

⁶⁵ Akcija, znotraj katere lahko TK člani sami izberejo do 10 artiklov (iz kataloga »Mojih 10«) ter jih nato za obdobje akcije kupujejo občutneje ceneje.

⁶⁶ Prodajno direktno pošto je možno še dodatno razdeliti na izdelčno (popust na določene artikle) ali na splošno (popust na celotno vrednost nakupa).

⁶⁷ V večini primerov je odziv novčitev kupona iz direktne pošte.

⁶⁸ Zaradi poslovne skrivnosti ne podajam konkretnih števil in vsebinskega opisa segmenta.

⁶⁹ Za potrebe magistrskega dela nisem prejela vseh podatkov, ki so shranjeni v podatkovnem skladišču trgovca Tuš (podatki o bonitetah, podatki o odzivih na trženjske aktivnosti, podatki o prejetih direktnih poštah, podatki o trženjskih aktivnostih: obdobje, artikli v akciji, popusti ...).

Tabela 5.2: Prikaz razlike v profilu segmentov po izbranih atributih glede na celoten vzorec TK članov.

izbrani atributi	celoten vzorec		
	TK članov	ZVESTI_TOP	LBZ_TOP
AVG ⁷⁰ _SKUPAJ_VRED_PRO	1	2,91	2,63
AVG_SKUPAJ_KOLIČINA	1	2,85	2,78
AVG_SKUPAJ_RAČUNOV_N	1	2,29	2,27
AVG_SKUPAJ_ARTIKLOV_N	1	2,12	2,00
AVG_SKUPAJ_PE_RAZLIČNIH_N	1	1,04	1,03
AVG_SKUPAJ_TUŠ_DEJAVNOST_N	1	1,04	1,01
AVG_SKUPAJ_VRED_PRO_LBZ	1	2,87	3,69
AVG_SKUPAJ_DELEŽ_LBZ_VRED_PRO	1	1,02	1,55
AVG_SKUPAJ_KOLIČINA_LBZ	1	2,80	3,74
AVG_SKUPAJ_KOLIČINA_LBZ_VRED_PRO	1	1,02	1,49
AVG_SKUPAJ_DELEŽ_DAN_y ⁷¹ _VRED_PRO	1	0,98	1,02
AVG_SKUPAJ_DELEŽ_URA_y ⁷² _VRED_PRO	1	1,06	1,09
AVG_SKUPAJ_DELEŽ_DEJAVNOST_y ⁷³ _VRED_PRO	1	0,58	0,40
AVG_SKUPAJ_DELEŽ_NAZIV_BS3 ⁷⁴ _313_VRED_PRO	1	1,03	1,07
AVG_SKUPAJ_DELEŽ_NAZIV_BS3_123_VRED_PRO	1	1,01	1,08
AVG_SKUPAJ_DELEŽ_NAZIV_BS3_114_VRED_PRO	1	0,85	0,58

Iz tabele 5.2 je razvidno, da se oba segmenta po profilu precej razlikujeta od splošne populacije oziroma celotnega vzorca TK članov (vrednost večja od 1 pomeni, da je izbrani atribut v segmentu bolj zastopan kakor v celotnem vzorcu TK članov; vrednost manjša od 1 pomeni, da je izbrani atribut v segmentu manj zastopan kakor v celotnem vzorcu TK članov). Zanimivo bi bilo analizirati še razliko v profilu članov Tuš kluba in nečlanov. Vendar to ni mogoče, saj Tuš ne zbira kontaktnih in demografskih podatkov nečlanov, kot to počne npr. Studio Moderna d.o.o..

⁷⁰ AVG je okrajšava za povprečno vrednost na segment.

⁷¹ Y je eden izmed dnevov v tednu (dneva ne razkrijem zaradi varovanja poslovne skrivnosti).

⁷² Y je eden izmed štirih razredov: 6:00 – 10:00; 11:00 – 14:00; 15:00 – 18:00; 19:00 – 5:00 (razreda ne razkrijem zaradi varovanja poslovne skrivnosti).

⁷³ Y je ena izmed dejavnosti Tuša (dejavnosti ne razkrijem zaradi varovanja poslovne skrivnosti).

⁷⁴ Za katero blagovno skupino gre ne razkrijem zaradi varovanja poslovne skrivnosti.

5.5.3 Evalvacija segmentov

Oba zgrajena segmenta – segment najbolj zvestih kupcev trgovcu oziroma skupini Tuš (TOP_ZVESTI) in segment najbolj zvestih kupcev trgovski lastni blagovni znamki (TOP_LBZ), imata naslednje značilnosti (Kotler 2004, 286; Kotler in Keller, 262):

- **merljivost:** pri obeh segmentih lahko trgovec na mesečni (kvartalni, polletni, letni ...) ravni meri velikost segmenta, prehajanje med segmenti, potrošnjo segmenta in značilnosti segmenta (demografske in nakupne);
- **velikost:** oba segmenta sta dovolj velika za izvajanje ciljanih in prilagojenih trženjskih aktivnosti;
- **dostopnost:** oba segmenta lahko trgovec učinkovito doseže (ima kontaktne podatke in dovoljenja za kontaktiranje) in nad njimi izvaja aktivnosti ciljanega trženja;
- **diferenciranost:** pri obeh segmentih so statistično značilne razlike med skupinama (DA/NE oziroma ZVESTI/NEZVESTI) glede na demografske značilnosti, ter prav tako se oba segmenta razlikujeta glede na celotno populacijo Tuš kupcev: razlika v potrošnji, v odzivih na trženjske aktivnosti, v nakupnem vedenju;
- **operativnost:** za pritegnitev in oskrbo obeh segmentov lahko trgovec oblikuje uspešne trženjske aktivnosti oziroma je sposoben, da uporabi novo pridobljeno znanje tudi v praksi.

5.6 Analiza nakupne košarice

Pri analizi nakupne košarice je najprej potrebno razumeti taksonomijo blagovnih skupin, kot jo ima zastavljeno Tuš. Gre za tri nivojsko taksonomijo, ki je predstavljena na primeru v spodnji tabeli (glej tabelo 5.3).

Tabela 5.3: Obrazložitev taksonomije blagovnih skupin na primeru 495287 nakupnih košaric.

Nivo taksonomije	Naziv blagovne skupine	Število vrednosti	Manjkajoče vrednosti, nerazvrščeno	Primer 1	Primer 2
Najvišji nivo BS nivo 1	NAZIV_BS1	7	0 %	»SVEŽI PROGRAM«	»NEŽIVILA – MARKET PROGRAM«
Srednji nivo BS nivo 2	NAZIV_BS3	109	22 %	»KRUH IN PECIVO«	»MEHČALCI«
Najnižji nivo BS nivo 3	NAZIV_BS	1035	21 %	»KRUH PAKIRAN OSNOVNI«	»MEHČALCI PERILA«
Nivo artikla	ARTIKEL	45004	24 %	»KRUH JELENOV POLBELI HLEB 1kg PAK. ŽITO«	»MEHČ.SILAN SENSITIVE 2L HENKEL«

Že iz prvega pregleda podatkov, lahko povem nekaj opažanj in nasvetov. Taksonomija blagovnih skupin bi lahko bila bogatejša:

- Skoraj ena četrtnina artiklov ni kategorizirana. Možna bi bila kategorizacija izdelkov s (pol)avtomatskimi metodami. Tudi na najnižjem nivoju, na nivoju artikla ni vsebinske vrednosti – npr. NAZIV_ARTIKEL = »Neznani artikel« ali »Neznan artikel I0705400000075« itd.
- Taksonomija je precej plitka – ima le tri nivoje, pri čemer je najvišji nivo presplošen (»5 BLAGOVNA SKUPINA«, »NEŽIVILA – MARKET PROGRAM«, »SUHI PROGRAM«, »SVEŽI PROGRAM«, »ZAMRZNJENI PROGRAM«, »GORIVO«, »EMBALAŽA«) in nima uporabne vrednosti oziroma informativne vrednosti za trženjske aktivnosti pospeševanja prodaje. Analiza povezovalnih pravil na najvišjem nivoju ni smiselna. Taksonomija bi torej lahko bila bolj bogatejša. Globlja struktura bi vsekakor pomagala pri analizi nakupne košarice.

Po drugi strani pa je na nivoju artikla kategorizacija zelo podrobna. Tako ima vsak okus, vonj, velikost embalaže, barva, dobavitelj ... enoznačno identifikacijsko številko artikla (v nadaljevanju ID). Tako lahko ima vsebinsko isti artikel ogromno ID-jev (npr. »*JOGURT KAVNI 3,2 % 180 g LJ.MLEKARNE*«, »*JOGURT VANILIJA 180 g ML.CELEIA*« ...). Tako je iz vsebinskega stališča, (kaj kupec kupuje) za potrebe ciljanega trženja, nivo artikla preveč kategorizirana (npr. »*NOG.SENSATION ALPAKA LYC. ŠT. 10.5 POLZELA*«) in nosi manjšo vsebinsko vrednost kot tretji nivo v taksonomiji blagovnih skupin (npr. »*NOGAVICE ŽENSKÉ*«). Analiza povezovalnih pravil na nivoju artikla, za potrebe ciljanega trženja, tako ni primerna⁷⁵. Je pa res, da si trgovec na osnovi tako podrobne kategorizacije, pridobiva znanje o velikosti oblačil in številki obutve za vsakega posameznega kupca in za družinske člane. V praksi se takšne informacije samo shranjujejo in se ne uporabljajo v trženjskih aktivnostih.

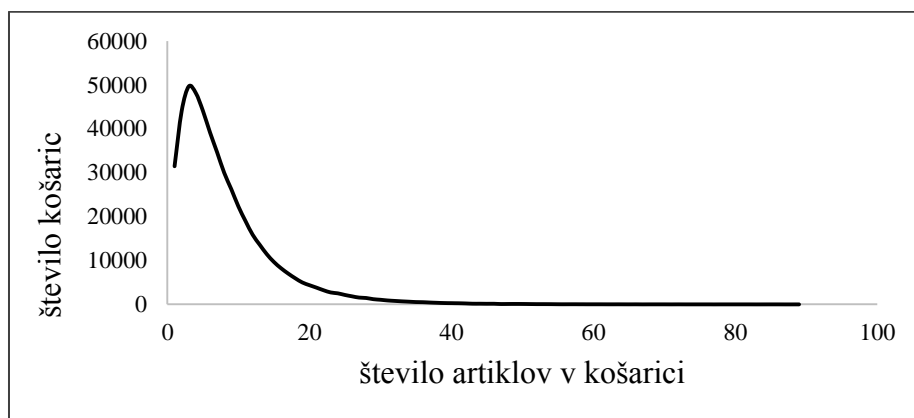
Prav zaradi zelo podrobne kategorizacije na nivoju artikla, bi zelo težko našla povezovalna pravila, ki prinašajo novo znanje in so hkrati dovolj pogosta, da so uporabna za aktivnosti ciljanega trženja (več o tem v naslednjem poglavju). Zaradi tehničnih omejitev, povezovalna pravila iščem na nivojih blagovnih skupin.

⁷⁵ Prav tako zaradi ogromnega števila artiklov, ni možno izvesti algoritma na domačem računalniku (procesor i7-4800MQ 2,70 GHz ter 16 GB spominskega prostora) in z namizno (angl. »*client*«) licenco, temveč je za to potrebna strežniška (angl. »*server*«) licenca, ki je plačljiva in ni na voljo za testno obdobje ali za študijske namene, ter prav tako bi po izkušnjah IBM-ja potrebovala vsaj 128 GB spominskega prostora.

5.6.1 Število artiklov v košaricah

Analiza števila artiklov v košarici kaže na porazdelitev podatkov, ki je značilna za take pojave. Število artiklov v košarici se vzpne do 89 v ekstremnih primerih, v običajnem primeru pa je le nekaj izdelkov v košarici⁷⁶. Slika 5.7 prikazuje porazdelitev števila artiklov na 495287 košaricah.

Slika 5.7: Porazdelitev števila artiklov v košarici.



5.6.2 Povezovalna pravila

Povezovalna pravila iščem samo na nakupnih košaricah, ki vsebujejo vsaj dva artikla in so iz dejavnosti Tuš trgovine – skupaj 461358 nakupnih košaric (število vrednosti: NAZIV_BS3 = 109, NAZIV_BS = 1035, ARTIKEL = 39961). V samem procesu analize podatkov, se je izkazalo, da je glede na tehnične omejitve (zmogljivost računalnika), podatkovna baza prevelika⁷⁷. Ni problem v številu objektov, temveč v številu atributov, zato sem dodatno izločila iz transakcij artikle, ki pri aktivnostih ciljanega trženja, s ciljem povečevanja zvestobe, nimajo velike informativne vrednosti⁷⁸ (gorivo, embalaža, neznani in nerazvrščeni artikli ter artikli, ki se prodajo v manjših količinah, predvsem se pa na njih ne izvajajo aktivnosti ciljanega trženja – to so artikli pete blagovne skupine: npr. bela tehnika, elektronika, oblačila, obutev, pohištvo ...). Tako dobim 441415 nakupnih košaric (4,3 % manj), 71 različnih blagovnih skupin na nivoju NAZIV_BS3, 648 na nivoju NAZIV_BS ter

⁷⁶ Aritmetična sredina = 8,207, standardni odklon = 6,911, mediana = 6, modus = 3.


⁷⁷ Algoritem se mi ni izvedel že na dvonivojskih povezovalnih pravilih – NAZIV_BS_NAZIV_BS3, ki ima skupno 1144 atributov.

⁷⁸ Trgovec Tuš na teh artiklih – razen izjem – ne izvaja aktivnosti ciljanega trženja.

18807 na nivoju ARTIKEL. Zaradi tehničnih omejitev, povezovalna pravila iščem na nivojih blagovnih skupin.

Da bi, zaradi zelo podrobne kategorizacije na nivoju artikla, zelo težko našla povezovalna pravila, ki prinašajo novo znanje in so hkrati dovolj pogosta, da so uporabna za aktivnosti ciljanega trženja, kaže že analiza na najnižjem nivoju blagovnih skupin (NAZIV_BS), kjer algoritem APriori omejim z minimalnim zaupanjem 45 %, minimalno podporo 1 % (ter dodatna omejitev maksimalno 5 artiklov oziroma predpogojev na pravilo), kar z vsebinskega (trženjskega) vidika zadostuje, saj je smiselno izvajati trženjske aktivnosti le na podlagi znanja, ki ga pokriva dovolj veliko število nakupnih košaric. Vendar že na nivoju NAZIV_BS, pri teh omejitvah dobim samo 7 pravil (na višjem nivoju NAZIV_BS3 169 pravil). Najvišja podpora 13,2 % (NAZIV_BS3 54,0 %) strmo pade na 2,7 % (NAZIV_BS3 na 36,9 %), kar nakazuje, da pri teh omejitvah na nivoju artikla ne bi dobila nobenega pravila. Konkreten primer je prikazan v spodnji sliki (glej sliko 5.8).

Slika 5.8: Prikaz padanja podpore in števila ustvarjenih pravil glede na razpršenost podatkov na 441415 nakupnih košaricah.



Raziskovalno vprašanje, na katerega želim dobiti odgovor pri odkrivanju znanja s povezovalnimi pravili:

- Kako omejiti število ustvarjenih povezovalnih pravil, da dobim dovolj zanimivih pravil, ter da so hkrati dovolj pogosta, da so uporabna za aktivnosti ciljanega trženja? Kakšna je torej optimalna meja minimalne podpore in minimalnega zaupanja na primeru trgovca?

Na podlagi ročnega preizkušanja (eksperimentiranja) z različnimi nastavitvami minimalne meje zaupanja, minimalne meje podpore, maksimalnega števila artiklov v pravilu (predpogojev) na nižjem in višjem nivoju blagovnih skupin (oziroma na različni razpršenosti

podatkov), zaključim, da ne morem podati splošnega priporočila, kakšna je optimalna meja zaupanja in podpore (na primeru trgovca), da ustvarjena pravila prinašajo dovolj novega znanja in so hkrati dovolj pogosta za aktivnosti ciljanega trženja.

Na podlagi rezultatov empiričnega raziskovanja podajam splošno ugotovitev: »V vsaki podatkovni bazi trgovca je povezovalnih pravil ogromno, vendar niso vsa zanimiva in dovolj pogosta za uporabo pridobljenega znanja v aktivnostih ciljanega trženja. Zato je potrebno algoritem, ki ustvarja pravila, omejiti z minimalno mejo podpore in minimalno mejo zaupanja tako, da so pravila še vedno dovolj pogosta in hkrati dovolj zanimiva oziroma uporabna za aktivnosti ciljanega trženja. Pri čemer ne morem podati splošnega priporočila, kakšna je optimalna meja za obravnavano problemsko področje, ta je namreč odvisna od razpršenosti podatkov oziroma od taksonomije blagovnih skupin, od velikosti podatkovne baze in od razpoložljivih sredstev za aktivnosti ciljanega trženja. Z večanjem razpršenosti podatkov eksponentno pada število ustvarjenih pravil. Tako je z večanjem razpršenosti podatkov potrebno zmanjševati mejo podpore in zaupanja, pri čemer je na strani uporabnika, kako bo omejil algoritem. Uporabnik je dodatno omejen s tehničnimi zmogljivostmi, ki dodatno vplivajo na izbiro ustreznega pristopa k reševanju obravnavanega problema.«

V konkretnem primeru vzorca 441415 nakupnih košaric je razpršenost podatkov na nivoju artikla prevelika, bolj informativno in uporabno znanje se skriva na nivoju blagovnih skupin. In sicer na najnižjem nivoju NAZIV_BS je optimalna minimalna meja za podporo 1 % ter za zaupanje 25 % (2360 pravil); na nivoju NAZIV_BS3 za podporo 3 % ter za zaupanje 35 % (2551 pravil). Na najvišjem nivoju blagovnih skupin NAZIV_BS1 iskanje povezovalnih pravil ni smiselno. Glede na kategorizacijo blagovnih skupin v Tušu, so za potrebe ciljanega trženja najbolj uporabna povezovalna pravila na nivoju NAZIV_BS. Potrdijo se opažanja iz samega pregleda blagovnih skupin, da bi lahko bila taksonomija blagovnih skupin bogatejša.

Eksperimentirala sem tudi z obratno strategijo, da sem povečevala minimalno mejo podpore ter hkrati zmanjševala minimalno mejo zaupanja in maksimalno število predpogojev, pri čemer se je ta strategija izkazala kot neuporabna. Tako na najnižjem nivoju blagovnih skupin (NAZIV_BS) v vsakem primeru (ne glede na omejitve podpore in zaupanja) dobim pravila z maksimalnim številom predpogojev 1, torej pravila tipa $1 \rightarrow 1$. Prav tako se s povečevanjem minimalne meje podpore, manjša število ustvarjenih pravil, kljub hkratnem zmanjševanju minimalne meje zaupanja. Hkrati pravila postajajo vse manj informativna in vse manj

raznolika – število vsebinsko različnih predpogojev v celotni množici ustvarjenih pravil se manjša. Tako pri podpori 25 % in zaupanju 5 % dobim 38 pravil, pri čemer je v celotni množici ustvarjenih pravil predpogoj 1 sam artikel (*»SADJE SVEŽE OBČUTJIVO«*), medtem ko so popogoji splošni artikli in noben izmed množice pravil ne predstavlja novega znanja. Z izborom minimalnih mej (podpora 15 %; zaupanje 3 %), da dobim dovolj veliko število pravil (414), je različno število predpogojev (v celotni množici pravil) še vedno občutno premajhno – samo 5⁷⁹. Tudi na višjem nivoju NAZIV_BS3, pri podpori 15 % in zaupanju 3 %, še vedno dobim samo 7 različnih predpogojev⁸⁰. Prav tako je potrebno upoštevati, da more biti zaupanje dovolj veliko, da je pravilo uporabno. Zaupanje 3 % je premajhno, da bi bila pravila uporabna za aktivnosti ciljanega trženja – ponovno se potrdi, da je takšna strategija neuporabna.

Eksperimentiram tudi z več nivojskim iskanjem povezovalnih pravil (NAZIV_BS3, NAZIV_BS). Konkreten primer ustvarjenega pravila:

»NAZIV_BS3_SADJE in ZELENJAVA and NAZIV_BS_PIVO DOMAČE – PLOČEVINKE« → *»NAZIV_BS3_SVEŽE MESO«* (podpora 30,6 %; zaupanje 5,2 %; izboljšava 1,6; pravilo ID 774).

Vendar algoritem oba nivoja blagovnih skupin obravnava enakovredno, posledica je ogromno povečanje števila ustvarjenih pravil, pri čemer je večina pravil vsebovana že v drugem, bolj splošnem pravilu. Primer takšnega pravila, ki je vezan na zgornji primer:

»NAZIV_BS3_SADJE in ZELENJAVA and NAZIV_BS3_PIVO and NAZIV_BS_PIVO DOMAČE – PLOČEVINKE« → *»NAZIV_BS3_SVEŽE MESO«* (podpora 30,6 %; zaupanje 5,2 %; izboljšava 1,6; pravilo ID 2483).

Tako se čas za iskanje zanimivih pravil zelo poveča. Glede na taksonomijo blagovnih skupin in porabljen čas pri večnivojskih povezovalnih pravilih, zaključim, da so v konkretnem primeru bolj uporabna enonivojska povezovalna pravila na nivoju NAZIV_BS, saj mi dajo več uporabnih informacij (za potrebe ciljanega trženja⁸¹ pridem do vsebinsko istega zaključka, s tem da dobim dodatne informacije glede na vrsto svežega mesa), res pa je, da je potrebno zmanjšati stopnjo zaupanja ter da ne dobim pravila z vsemi tremi predpogoji (pivo,

⁷⁹ *»SADJE SVEŽE OBČUTJIVO«, »ZELENJAVA SVEŽA OBČUTLJ.«, »ZELENJAVA SVEŽA OBSTOJNA«, »KRUH SVEŽI OSNOVNI«* ter *»MLEKO TRAJNO«*.

⁸⁰ *»SADJE IN ZELENJAVA«, »KRUH IN PECIVO«, »MLEČNI PROGRAM«, »MESNI IZDELKI«, »MLEKO«, »BREZALKOHOLNE PIJAČE«* ter *»SLADKI PROGRAM«*.

⁸¹ Npr. personalizirana direktna pošta s kuponi s ciljem pospeševanja prodaje svežega svinjskega mesa. Kupon 1: *»Ob hkratnem nakupu 3 različnih vrst svežega sadja ali zelenjave – 20 % popust na sveže svinjsko meso.«* Kupon 2: *»Ob nakupu PIVO UNION svetlo, pločevinke, 6 x 0,5 l – 20 % popust na sveže svinjsko meso.«*

zelenjava, sadje) hkrati. Primeri povezovalnih pravil za zgornji primer na nivoju NAZIV_BS so naštet v prilogi C (glej PRILOGO C).

Povezovalna pravila na nivoju NAZIV_BS in NAZIV_BS3 nadgradim z večdimenzionalnimi povezovalnimi pravili – dodam podatek o spolu, starosti in regiji kupca. Primer konkretnega pravila:

»NAZIV_BS_TUNE – KONZERVE and REGIJA_IME_Pomurska and SPOL_moški« → »NAZIV_BS_HRANA ZA PSE BRIKETI« (podpora 0,1 %; zaupanje 41,0 %, izboljšava 35,6),

»NAZIV_BS_HRANA ZA MAČKE ALU and STAROST_STAROST = > 65 and NAZIV_BS_MLEKO TRAJNO and SPOL_ženski« → »NAZIV_BS_HRANA ZA MAČKE BRIKETI« (podpora 0,14 %; zaupanje 27,3 %; izboljšava 17,3).

Z raziskovanjem večdimenzionalnih pravil dobim največ zanimivih pravil in tako na novo pridobljenega znanja. Predvsem so uporabna za aktivnosti ciljanega trženja, kadar ciljamo na zelo specifične majhne segmente, kadar nas zanimajo zelo specifična pravila (nizka podpora, visoko zaupanje), kadar imamo omejena sredstva za aktivnosti ciljanega trženja (npr. direktno pošto lahko pošljemo samo na zelo majhno bazo kupcev in želimo, da je odziv čim večji: ciljamo kupce določenega spola iz določene regije in v določeni starosti; če je baza še vedno prevelika, dodatno gledamo, da kupujejo določene blagovne skupine), za namene testiranja prepričanij uporabnikov – npr. prepričanje vodstva, da moški ne kupujejo plenice, v nasprotju prepričanja oddelka trženja, da lahko s prilagojeno aktivnostjo ciljanega trženja moškim prodajo plenice enako uspešno kot ženskam. V konkretnem primeru lahko oddelek trženja, ob predložitvi rezultatov analize večdimenzionalnih povezovalnih pravil, pridobi od vodstva dodatna finančna sredstva, za testiranje prilagojene aktivnosti ciljanega trženja s ciljem pospeševanja prodaje plenice moški populaciji. Konkreten primer iz vzorca 441415 nakupnih košaric:

»NAZIV_BS_OTROŠKI ROBČKI, BRISAČKE and STAROST_30<=STAROST<45 and SPOL_ženski« → »NAZIV_BS_PLENICE 9,5 %« (podpora 0,24 %, zaupanje 10,85 %, izboljšava 41,2; pravilo ID 6) ter

»NAZIV_BS_OTROŠKI ROBČKI, BRISAČKE and SPOL_moški« → »NAZIV_BS_PLENICE 9,5 %« (podpora 0,14 %, zaupanje 11,92 %, izboljšava 45,27; pravilo ID 18).

Lahko pa me zanima ravno obratno raziskovalno vprašanje: katere artikle večja množica kupcev pogosto kupuje skupaj oziroma kateri artikli se pojavljajo najpogosteje v nakupni košarici? Pomembno je torej, da je podpora pravila velika, ob minimalno določeni meji zaupanja. Iščem torej artikle, ki se pogosto pojavljajo skupaj v nakupni košarici. Za ta namen

iščem povezovalna pravila na nivoju blagovne skupine NAZIV_BS, saj je bolj uporabna in informativna za potrebe ciljanega trženja, kot blagovna skupina na višjem nivoju NAZIV_BS3. Kot rezultat dobim množico pravil (glej PRILOGO Č) z maksimalno podporo oziroma pravila, ki se pojavljajo skupaj enako pogosto (podpora 29,2 % oziroma 128962 transakcij). Med to množico pravil, so najbolj zanimiva tista pravila, ki imajo najmanjše zaupanje.

Intuitivno (če se postavim v kožo kupca) nisem pričakovala zanimivih rezultatov – temveč povezovalna pravila zelo splošnih artiklov vsakdanje uporabe (kombinacije blagovnih skupin: kruh, mleko, sadje, zelenjava, meso). Najbolj pogosta povezovalna pravila (pravila z največjim številom transakcij) so res kombinacije splošnih artiklov, vendar me je presenetilo, da se med njimi najdejo tudi artikli, za katere nisem pričakovala, da se tako pogosto pojavljajo v nakupni košarici in jih intuitivno nikakor ne bi uvrstila med artikle, ki se pojavljajo v večini nakupnih košaric (npr. konkretni primeri iz rezultatov: skuta navadna, hrenovke, brisače papirnate ...).

Ugotavljam, da se tudi med najbolj pogostimi povezovalnimi pravili (oziroma pravili z največjo mejo podpore) v podatkovni množici (na primeru trgovca) skriva novo znanje, ki ga brez analize povezovalnih pravil (oziroma intuitivno) ne bi odkrila.

Za vsebinsko nadgradnjo povezovalnih pravil, sem si zastavila dve dodatni raziskovalni vprašanji:

- Ali imajo stornirani računi vpliv na rezultate povezovalnih pravil oziroma ali jih je potrebno pri pripravi podatkov izločiti?
- Ali lahko s storniranimi računi dobim dodatno novo znanje, v primerjavi z vsemi računi brez stornacij?

Iz množice transakcij tako izločim stornirane račune (0,5 % oziroma 2285 nakupnih košaric) in algoritem APriori poženem na treh podatkovnih množicah (vse transakcije; transakcije brez storniranih računov; samo stornirane transakcije) pri enakih omejitvah (podpora 1 %; zaupanje 25 %; maksimalno število predpogojev 5; nivo blagovnih skupin NAZIV_BS). Osnovne statistike modela na vseh treh podatkovnih množicah so podane v spodnji tabeli na naslednji strani (glej tabelo 5.4).

Tabela 5.4: Osnovne statistike modela APriori (Po 1 %; Za 25 %) na treh podatkovnih množicah.

STATISTIKE	Vse transakcije	Brez storniranih transakcij	Samo stornirane transakcije
Število veljavnih transakcij	44145	439130	2285
Število ustvarjenih pravil	2360	2394	199
Minimalna podpora	1 %	1 %	1,007 %
Maksimalna podpora	29,216 %	29,226 %	17,637%
Minimalno zaupanje	25 %	25 %	25 %
Maksimalno zaupanje	60,88 %	60,914 %	56,522 %
Minimalna izboljšava	0,898	0,899	0,92
Maksimalna izboljšava	10,275	10,263	11,688

Vsebinskih razlik med povezovalnimi pravili na vseh transakcijah in na transakcijah brez stornacij ni. Podam splošno ugotovitev: *kadar je število storniranih računov manjše od 1 %, se jih lahko pri analizi povezovalnih pravil zanemari, brez da bi pri tem izgubili pomembne vsebinske informacije (oziroma jih ni potrebno izločati v procesu priprave podatkov).*

Ob pregledu vseh 199 pravil na podatkovni množici storniranih transakcij, ni pravila, ki ne bi bil vsebovan že v podatkovni množici brez storniranih transakcij (kar je bilo tudi pričakovati zaradi izredno majhnega odstotka storniranih računov, 0,5 %). S storniranimi računi tako ne pridobim dodatnega novega znanja. A vendarle je lahko za trgovca analiza povezovalnih pravil na storniranih nakupnih košaricah uporabna, kadar so vsebinski problem stornacije – ko želi ugotoviti katere artikle kupci najpogosteje vračajo in želi ugotoviti vzroke za vračanje letih. To je še posebej primerno pri trgovcih, ki v večini prodajajo ne-prehrambne ter ne-drogerijske artikle (npr. v Sloveniji: Studio Moderna d.o.o., Merkur trgovina d.d. ...), kjer je odstotek zavrnjenih računov tudi nad 20 %.

V konkretnem primeru povezovalna pravila z največjim zaupanjem vsebujejo blagovne skupine: zelenjava sveža obstojna, zelenjava sveža občutljiva, sadje sveže občutljivo. Vendar je takšnih stornacij občutno premalo, da bi lahko zaključila, da ima trgovec probleme s svežino sadja in zelenjave.

5.6.3 Priporočila artiklov

Za vsako blagovno skupino (na najnižjem nivoju) v bazi sem izračunala, katere so najbolj sorodne blagovne skupine artiklov. Informacija trgovcu omogoča:

- identifikacijo povezanih artiklov in blagovnih skupin,
- načrtovanje razporeditve artiklov po policah (strategija je lahko takšna, da se kupcu olajša nakup – artikli se postavijo skupaj, na isto ali bližnjo polico ali pa je strategija ravno obratna – artikli se postavijo daleč narazen, kar prisili kupca, da pregleda tudi ostale potencialne artikle za nakup),
- oblikovanje paketov ponudbe po meri kupca,
- povečati odziv na ciljno trženjsko aktivnost (vezana prodaja, rezultati služijo kot predlogi za ponujanje novih in nadgradnjo obstoječih artiklov, predlogi za kupone v direktni pošti ...) ter
- v primeru personalizirane ponudbe in popustov lahko s pomočjo te informacije maksimizira zadovoljstvo in zvestobo kupca ter profit za trgovino.

Kot primer sem vzela personalizirano direktno pošto trgovca Tuš »Izkoristite kupone za atraktivne popuste!« z veljavnostjo 3. 2. 2016 do 16. 2. 2016 oziroma do razprodaje zalog (za sliko celotne direktne pošte glej PRILOGO D). Spodaj podajam primer za: kupon 50 % popust na mehčalce perila SILAN (glej sliko 5.9 in tabelo 5.5); kupon 30 % na detergente za ročno pomivanje posode PRIL (glej sliko 5.10 in tabelo 5.6); kupon 40 % na pralne praške PERSIL, kupon 50 % na pralne praške REX ter 30 % popust na detergente za občutljivo perilo PERWOLL (glej sliko 5.11 in tabelo 5.7). V tabeli prikažem samo najboljše priporočila po kriteriju **izboljšave** (angl. »lift, improvement«; okrajšano Iz), pri čemer so blagovne skupine na kuponih predpogoji, priporočila pa popogoji. Bolj podrobne informacije (podpora, zaupanje) so navedene v PRILOGI E.

Slika 5.9: Kupon 50 % na mehčalce perila SILAN.



Vir: Personalizirana direktna pošta pošte trgovca Tuš z veljavnostjo 3. 2. 2016 do 16. 2. 2016.

Tabela 5.5: Primer priporočil za blagovno skupino MEHČALCI PERILA.

Priporočilo	Iz	Priporočilo	Iz
NAZIV_BS_PRALNI PRAŠKI – KAPSULE	6,5	NAZIV_BS_DETER.STR.POM.POS – GEL	3,5
NAZIV_BS_PRALNI PRAŠKI – PRAH	6,2	NAZIV_BS_PENEČE KOPELI IN SOLI	3,3
NAZIV_BS_PRALNI PRAŠKI – GELI,TEKOČ.	5,9	NAZIV_BS_WC OBEŠANKE – TEKOČE	3,2
NAZIV_BS_DETERG.ZA OBČUTLJ.PERILO	5,5	NAZIV_BS_DETER.ZA ROČNO POM.POSODE	3,2
NAZIV_BS_ODSTRANJEVALCI MADEŽEV	4,7	NAZIV_BS_DETER.STR.POM.POS-SOLI	3,2
NAZIV_BS_SREDS.ZA PREPRE VOD.KAMNA	4,4	NAZIV_BS_ČISTILA – VODNI KAMEN	3,2
NAZIV_BS_ČISTILA – KOPALNICE	4,0	NAZIV_BS_ČISTILA – LES, PRAH	3,2
NAZIV_BS_ČISTILA – KUHINJA	3,9	NAZIV_BS_DESTILIRANA VODA	3,1
NAZIV_BS_BELILA, APRETURE, ŠTIRKE	3,8	NAZIV_BS_DETER.STR.POM.POS – SIJAJ	3,1
NAZIV_BS_DETER.STR.POM.POS-TABLETE	3,7	NAZIV_BS_OSVEŽILCI PROST.-KLIK SP.	3,1
NAZIV_BS_WC OBEŠANKE – GELI	3,6	NAZIV_BS_ČISTILA – TALNE POVRŠINE	3,1
NAZIV_BS_ČISTILA – UNIVERZALNA	3,6	NAZIV_BS_OTROŠKI ŠAMPONI, BALZAMI	3,1
NAZIV_BS_OSVEŽILCI PROST. – ELEKTRIČ	3,6	NAZIV_BS_DEODORANTI – STICK ŽENSKI	3,1
NAZIV_BS_ČISTILA – STEKLO	3,6	NAZIV_BS_TUŠ GELI	3,1
NAZIV_BS_ČISTILA ZA WC	3,5	NAZIV_BS_KRPE, GOBE – ŽIČNE, VOLNA	3,0
NAZIV_BS_WC OBEŠANKE – TRDE	3,5	NAZIV_BS_BALZAMI ZA LASE	3,0

Priporočila za blagovno skupino MEHČALCI PERILA so tako vsi artikli iz blagovne skupine PRALNI PRAŠKI, kakršna koli ČISTILA (za kopalnico, za kuhinjo, za pohištvo, za pomivanje posode ...), OSVEŽILCI PROSTORA ter DROGERIJSKA KOZMETIKA (artikli za nego telesa, artikli za nego las, otroška kozmetika ...). Ker se mehčalci perila in pralni praški skoraj vedno kupujejo skupaj, bi bilo smiselno testirati različne koncepte trženjske aktivnosti, kjer se hkrati ne ponujajo popusti na obe skupini – izziv je torej kako eno blagovno skupino prodati po redni ceni (npr. ob nakupu pralnega praška po redni ceni je nagrada mehčalec perila za 1 cent). Prav tako bi lahko nakup mehčalca perila vezali na nakup artiklov iz drogerijske kozmetike (mehčalec perila po redni ceni ter popust na drogerijski artikel), pri čemer bi bilo posebej zanimivo testirati razliko v odzivu glede na vrsto drogerijskega izdelka: otroški drogerijski izdelek, splošen drogerijski izdelek (npr. šampon, balzam za lase, tuš geli, zobne paste ... – ločen test za žensko, moško in splošno kozmetiko), drogerijski izdelek za razvajanje (kopeli, spa program ...) ter dražji drogerijski izdelek (parfumi, darilni seti, kozmetične torbice, sušilci za lase ...).

Slika 5.10: Kupon 30 % na detergente za ročno pomivanje posode PRIL.



Vir: Personalizirana direktna pošta pošte trgovca Tuš z veljavnostjo 3. 2. 2016 do 16. 2. 2016.

Tabela 5.6: Primer priporočil za blagovno skupino DETERGENTI ZA ROČNO POMIVANJE POSODE.

Priporočilo	Iz	Priporočilo	Iz
NAZIV_BS_KRPE, GOBE – ŽIČNE, VOLNA	5,2	NAZIV_BS_KAVOVINE	3,4
NAZIV_BS_ČISTILA ZA WC	4,9	NAZIV_BS_BELILA, APRETURE, ŠTIRKE	3,3
NAZIV_BS_ČISTILA – KUHINJA	4,9	NAZIV_BS_ODSTRANJEVALCI MADEŽEV	3,2
NAZIV_BS_KRPE, GOBE – GOSPODINJSKE	4,7	NAZIV_BS_DETERG.ZA OBČUTLJ.PERILO	3,2
NAZIV_BS_ČISTILA – UNIVERZALNA	4,6	NAZIV_BS_MEHČALCI PERILA	3,2
NAZIV_BS_ČISTILA – VODNI KAMEN	4,6	NAZIV_BS_OSVEŽILCI PROST. – SPREJI	3,2
NAZIV_BS_ČISTILA – KOPALNICE	4,5	NAZIV_BS_RIŽ OSNOVNI	3,2
NAZIV_BS_ČISTILA – STEKLO	4,5	NAZIV_BS_OLJE SOLATNO	3,2
NAZIV_BS_ČISTILA – LES, PRAH	4,0	NAZIV_BS_WC OBEŠANKE – TRDE	3,2
NAZIV_BS_ČISTILA – TALNE POVRŠINE	4,0	NAZIV_BS_SOL	3,1
NAZIV_BS_MILO TOALETNO	4,0	NAZIV_BS_PRALNI PRAŠKI – GELI,TEKO.	3,1
NAZIV_BS_SREDS.ZA PREPRE VOD.KAMNA	3,9	NAZIV_BS_PRALNI PRAŠKI – KAPSULE	3,1
NAZIV_BS_DETER.STR.POM.POS – SIJAJ	3,8	NAZIV_BS_MILO INTIMNO	3,1
NAZIV_BS_WC OBEŠANKE – GELI	3,8	NAZIV_BS_PENEČE KOPELI IN SOLI	3,1
NAZIV_BS_PRALNI PRAŠKI – PRAH	3,8	NAZIV_BS_JUHE INSTANT KOCKE	3,0
NAZIV_BS_WC OBEŠANKE – TEKOČE	3,7	NAZIV_BS_ŠAMPONI	3,0
NAZIV_BS_DETER.STR.POM.POS – GEL	3,7	NAZIV_BS_OLJE RASTLINSKO	3,0
NAZIV_BS_OSVEŽILCI PROST. – KLIK SP.	3,6	NAZIV_BS_BRISAČE PAPIRNATE	3,0
NAZIV_BS_MILO TEKOČE	3,5	NAZIV_BS_TESTENINE DOLGE	3,0
NAZIV_BS_DETER.STR.POM.POS – SOLI	3,5	NAZIV_BS_BALZAMI ZA LASE	3,0
NAZIV_BS_DETER.STR.POM.POS –TABLETE	3,4	NAZIV_BS_TUŠ GELI	3,0
NAZIV_BS_DODATKI JEDEM KOZARČKI	3,4		

Priporočila za blagovno skupino DETERGENTI ZA ROČNO POMIVANJE POSODE nudijo dodatne priložnosti za vezano prodajo tudi na osnovne prehranske artikle (riž, testenine, olje, kava). Tako bi lahko v direktni pošti pospeševali prodajo dražjih artiklov iz teh blagovnih skupin (npr. oljčno olje, polnozrnat testenine ...). Prav tako bi lahko testirali koncept ob

hkratnem nakupu treh detergentov za ročno pranje, po redni ceni je nagrada 100 gramov Tuš Zlate kave za 1 cent.

Slika 5.11: Kupon 50 % na pralne praške REX, kupon 40 % na pralne praške PERSIL in kupon 30 % popust na detergente za občutljivo perilo PERWOLL.



Vir: Personalizirana direktna pošta pošte trgovca Tuš z veljavnostjo 3. 2. 2016 do 16. 2. 2016.

Tabela 5.7: Primer priporočil za blagovno skupino PRALNI PRAŠKI ter DETEREGENTI ZA OBČUTLJIVO PERILO.

Priporočilo	Iz	Priporočilo	Iz
NAZIV_BS_ODSTRANJEVALCI MADEŽEV	9,2	NAZIV_BS_ČISTILA – STEKLO	3,7
NAZIV_BS_SREDS.ZA PREPRE VOD.KAMNA	6,7	NAZIV_BS_MILO TOALETNO	3,7
NAZIV_BS_MEHČALCI PERILA	6,2	NAZIV_BS_DETER.STR.POM.POS – SOLI	3,6
NAZIV_BS_DETER.STR.POM.POS –TABLETE	6,0	NAZIV_BS_WC OBEŠANKE – TEKOČE	3,4
NAZIV_BS_SREDS.ZA PREPRE VOD.KAMNA	5,3	NAZIV_BS_ČISTILA – TALNE POVRŠINE	3,4
NAZIV_BS_BELILA, APRETURE, ŠTIRKE	5,2	NAZIV_BS_PENE ZA LASE	3,4
NAZIV_BS_ČISTILA ZA WC	4,6	NAZIV_BS_WC OBEŠANKE – GELI	3,3
NAZIV_BS_ČISTILA – VODNI KAMEN	4,6	NAZIV_BS_DETER.STR.POM.POS – GEL	3,3
NAZIV_BS_ČISTILA – KUHINJA	4,1	NAZIV_BS_BELILA, APRETURE, ŠTIRKE	3,3
NAZIV_BS_ČISTILA – UNIVERZALNA	4,1	NAZIV_BS_IZDELKI PROTETIKE	3,2
NAZIV_BS_ČISTILA – LES, PRAH	4,1	NAZIV_BS_KRPE, GOBE – GOSPODINJSKE	3,2
NAZIV_BS_PENEČE KOPELI IN SOLI	4,1	NAZIV_BS_DESTILIRANA VODA	3,2
NAZIV_BS_KRPE, GOBE – ŽIČNE, VOLNA	4,0	NAZIV_BS_OLJE SOLATNO	3,1
NAZIV_BS_OSVEŽILCI PROST. – ELEKTRIČ	4,0	NAZIV_BS_ČISTILA – KOPALNICE	3,0
NAZIV_BS_DETER.STR.POM.POS – SIJAJ	3,9	NAZIV_BS_LAKI ZA LASE	3,0
NAZIV_BS_WC OBEŠANKE – TRDE	3,9	NAZIV_BS_OTROŠKI ŠAMPONI, BALZAMI	3,0
NAZIV_BS_DETER.ZA ROČNO POM.POSODE	3,8		

Zelo zanimivo priporočilo ter vsekakor novo uporabno znanje za blagovno skupino PRALNI PRAŠKI, so izdelki iz blagovne skupine IZDELKI PROTETIKE. Glede na to informacijo bi bilo zanimivo testirati vezano prodajo pralnih praškov z artikli za potrebe starejše populacije (seniorjev) ter z artikli za zdravje (vitaminski ter prehranski dodatki).

5.6.4 Evalvacija povezovalnih pravil

Z APriori algoritmom sem dobila ogromno povezovalnih pravil, vendar niso vsa uporabna. Pravila sem razdelila na:

- **nezanimiva pravila**⁸² – ki se ujemajo z nakupovalnimi navadami večine kupcev in jih lahko ugotovim tudi brez analize povezovalnih pravil – torej ne predstavljajo novega znanja,
- **zanimiva**⁸³ – odkrivajo novo znanje, **vendar so že vsebovana v drugih zanimivih pravilih**⁸⁴ ter
- **zanimiva, ki odkrivajo novo znanje** oziroma odkrivajo nepričakovan vzorec, ki ga s težavo pojasnim⁸⁵. Tukaj je potrebna evalvacija s strani strokovnega uporabnika (s strani trženja pri lastniku podatkov). Ta pravila so uporabna informacija za testiranje različnih ciljanih trženjskih aktivnosti za pospeševanje prodaje in za povečevanje zvestobe TK članov.

⁸² Npr. »NAZIV_BS_SADJE SVEŽE OBČUTLJIVO« → »NAZIV_BS_ZELENJAVA SVEŽA OBSTOJNA« (Po 29,2 %; Za 30,9 %; Iz 1,4).

⁸³ »NAZIV_BS_HRANA ZA MAČKE ALU and STAROST_STAROST = > 65 and SPOL_ženski« → »NAZIV_BS_HRANA ZA MAČKE BRIKETI« (Po 0,6 %; Za 12,5 %; Iz 7,9).

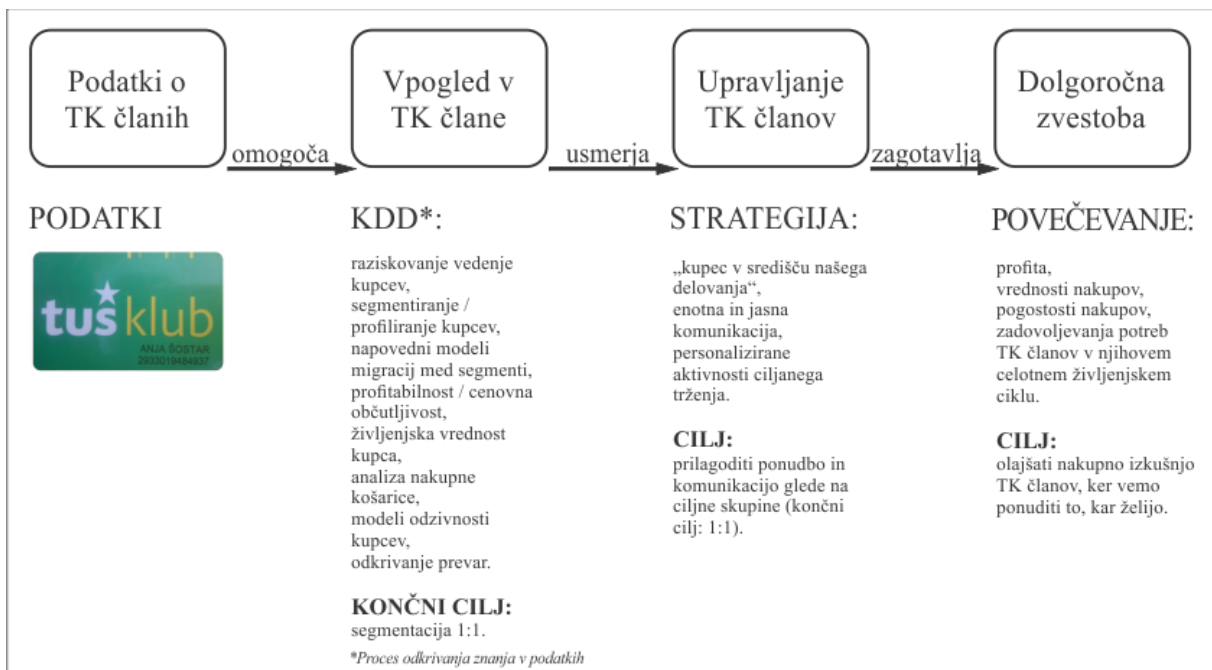
⁸⁴ »NAZIV_BS_HRANA ZA MAČKE ALU and STAROST_STAROST = > 65 and NAZIV_BS_MLEKO TRAJNO and SPOL_ženski« → »NAZIV_BS_HRANA ZA MAČKE BRIKETI« (Po 0,14 %; Za 27,3 %; Iz 17,3).

⁸⁵ Npr. »NAZIV_BS_IZDELKI PROTETIKE« → »NAZIV_BS_PRALNI PRAŠKI – PRAH« (Po 0,2 %; Za 5,9 %; Iz 3,2).

5.7 Uporaba odkritega znanja na primeru trgovca Tuš

Rezultati celotnega procesa odkrivanja znanja v podatkih (glej sliko 5.12) ter eksperimentiranja z različnimi tehnikami podatkovnega rudarjenja, so informacije z veliko potencialno vrednostjo za trgovca Tuš – za povečevanje prodaje, povečevanje profita, zmanjševanje stroškov ter povečevanje zvestobe kupcev.

Slika 5.12: Predlagan konkretni model uporabe odkrivanja znanja v podjetju Engrotuš d.d..



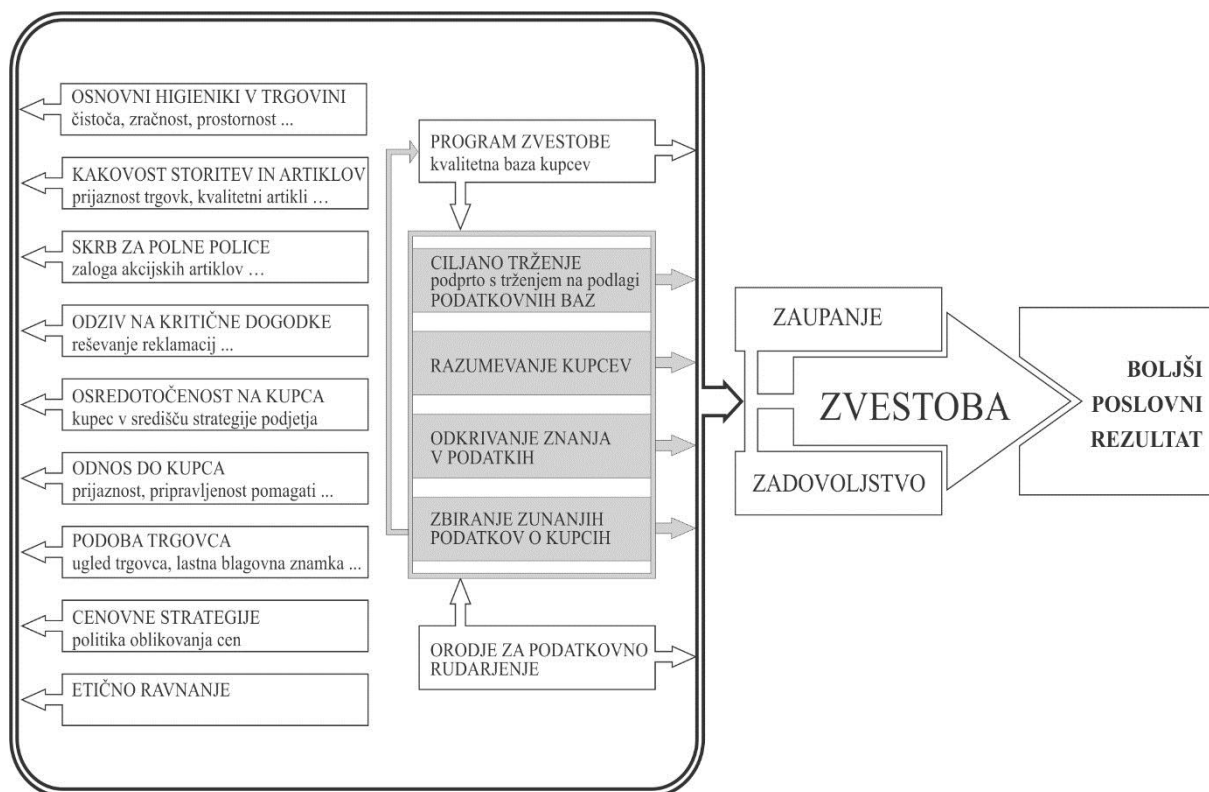
Največja vrednost programa Zvestobe Tuš klub je torej znanje, ki se skriva v podatkih. Vendar sam proces odkrivanja znanja ni dovolj – pridobljeno znanje je potrebno uporabiti v praksi, v aktivnostih ciljanega trženja. Vendar tudi *podatki, znanje in aktivnosti niso dovolj za povečevanje zvestobe Tuš klub članov – potrebna je jasna, iskrena, konsistentna in personalizirana komunikacija na vseh nivojih* (prodajna mesta, komunikacijski materiali, komunikacijski kanali, prodajno osebje), ki govori iskreno in v en glas.

V naslednjem poglavju predstavim predlog modela, ki formalno opisuje in rešuje raziskovalni problem magistrske naloge – povečevanje zvestobe kupcev.

6 PREDLOG MODELA ZA POVEČEVANJE ZVESTOBE KUPCEV

Ob podrobnejšem pregledu literature in praks v tujini, na poznavanju poslovnih potreb v podjetjih (s poudarkom na trgovcih) ter na podlagi rezultatov empiričnega raziskovanja sem izdelala predlog modela, ki formalno opisuje in rešuje raziskovalni problem magistrske naloge – povečevanje zvestobe kupcev. V modelu se omejujem samo na dejavnike za povečevanje zvestobe, na katere lahko trgovci neposredno vplivajo: v relativno kratkem času ter z majhnimi dodatnimi stroški (npr. lokacija trgovine je zelo pomemben dejavnik za obisk trgovine, vendar je nerealno pričakovati, da bo vsak trgovec povečeval število trgovin, da se približa posameznemu kupcu). Vzporedno z interpretacijo modela podam v tem poglavju tudi predloge izboljšav in rešitev pri povečevanju zvestobe kupcev. Sam model je shematsko prikazan na spodnji sliki (glej sliko 6.1).

Slika 6.1: Shema zgrajenega teoretičnega modela za povečevanje zvestobe kupcev na primeru poslovnega okolja trgovca.



Za povečevanje zvestobe kupcev in za boljši poslovni rezultat trgovca so – zelo grobo opredeljeno – ključni naslednji dejavniki:

- dejavniki, ki vplivajo na zaupanje kupcev,
- dejavniki, ki vplivajo na zadovoljstvo kupcev,
- dejavniki, ki vplivajo na poznavanje in razumevanje kupcev ter
- dejavniki, ki vplivajo na trgovčev potencial za izkoriščanja pridobljenega znanja o kupcih preko ciljanega trženja.

Vsi zgoraj omenjeni dejavniki se lahko medsebojno prepletajo (ena izkušnja kupca vedno zajame več dejavnikov), pri čemer je en sam dejavnik nujen pogoj za zvestobo, ni pa zadosten pogoj.

Osnovni higieniki v trgovini (primerna osvetljenost, prostornost, prehodnost, čistoča, parkirni prostori ...) so temeljni dejavnik, na osnovi katerega lahko trgovec gradi zadovoljstvo kupcev. Moj predlog je, da bi trgovci morali več pozornosti posvetiti čistoči nakupovalnih vozičkov ter doslednosti in opozarjanju kupcev, da vozijo otroke v za to namenjenih sedalih na nakupovalnih vozičkih.

Kakovost artikla ali storitve, ki jo zazna kupec, je eden ključnih dejavnikov pri oblikovanju zadovoljstva. Tukaj je pomembno kaj kupec misli (subjektivna ocena s strani kupca) in ne dejanska kakovost artikla/storitve. Če pričakovanja dosegajo ali celo presegajo dejansko kakovost, je kupec zadovoljen oziroma zelo zadovoljen, v nasprotnem primeru (nedoseganju) je nezadovoljen. K ohranjanju in vzdrževanju zadovoljstva in predvsem zaupanja, močno vpliva dosledna **skrb za polne police** oziroma skrb za zalogo akcijskih artiklov.

Na preživetje trgovca odločilno vplivajo **cenovne strategije oziroma politika oblikovanja cen** – najširši in osnovni cilj oblikovanja cen je, da si trgovec s ceno pokrije stroške, ustvari minimalni dobiček (po potrebi pokrije kratkoročno izgubo) ter, da si s pošteno in etično cenovno strategijo zagotavlja zvestobo kupcev.

Naslednji dejavnik, ki pomembno vpliva na zadovoljstvo, zaupanje in zvestobo je **kakovost odnosa do kupca**. Odnos, ki se razvije med kupcem in zaposlenimi v trgovini (na reklamacijskem oddelku ...), je lahko odločilen dejavnik njegovega vračanja in ponovnega nakupovanja. Neprijaznost, vsiljivost, brezbrižnost, neizobraženost ali vzvišenost zaposlenih

lahko povzroči, da se kupec v zadnjem hipu »odpove« nakupu. Zato so zelo pomembne strategije trgovca za spodbujanje prodaje in upravljanje s človeškimi viri. Trgovci bi morali več pozornosti posvetiti usposabljanju zaposlenih (vseh zaposlenih, ki imajo kakršen koli stik s kupcem) ter za razvijanje in utrjevanje spretnosti, ki prispevajo k pridobivanju zaupanja kupcev in k razvoju dolgotrajnih odnosov s kupci (predvsem na področja povezana s psihologijo kupcev).

Podoba trgovca (podoba **trgovskih blagovnih znamk**, prodajaln ...) je naslednji pomemben dejavnik za vračanje kupcev. Je kupčeva splošna subjektivna ocena, za katero je značilno, da je trajna ter je seštevek preteklih izkušenj, informacij, oglaševanja, vrednot trgovca ... Pomembno vpliva tudi na stopnjo zadovoljstva, na zaznano vrednost kakovosti izdelkov/storitev, na odnos kupca do trgovca in obratno. Kupce namreč privlačijo trgovci (trgovske blagovne znamke), katerih identiteta se ujema z njihovimi osebnimi interesi, stališči, pričakovanji in vrednotami.

Strategija osredotočenosti na kupca je za pridobivanje, ohranjanje in povečevanje zvestobe kupcev nedvomno izjemno pomembna. Vendar samo zapisana strategija ni dovolj, pomembno je, kako je trgovec sposoben dosledno in sistematično izvajati strategijo v praksi – pri čemer je osnovni predpogoj sposobnost prisluhni kupcem (znanje o kupcih) in jim odgovoriti s ponudbo, ki učinkovito nagovori in zadovolji njihove potrebe, pričakovanja, želje.

Vendar, če se trgovec osredotoči zgolj na razloge za zadovoljstvo kupcev, lahko zanemari razloge za nezadovoljstvo⁸⁶. Napačno je predpostavljati, da so strategije za povečevanje zadovoljstva zadostno orodje za preprečevanje nezadovoljstva. Zato je zelo pomembno ugotovljati in razumeti, kateri kupci so nezadovoljni in zakaj. To trgovcu omogoča razviti učinkovite strategije za ravnanje z nezadovoljnimi kupci ter jim preprečiti odhod drugam, še preden odidejo. Zelo pomemben dejavnik je tako reševanje in rešitve kupčevih problemov, reklamacij ali pritožb oziroma **odziv na kritične dogodke**.

Strateški pristop k zagotavljanju strategije osredotočenosti na kupca, k zadovoljstvu in zaupanju kupca, je tem bolj učinkovit, kolikor bolj je osredotočen na **razumevanje kupcev** in njihovih potreb. Temelji učinkovite strategije morajo biti zanesljivi podatki na nivoju kupca,

⁸⁶ Nezadovoljstvo je eden od osnovnih vzrokov za odhode kupcev h konkurenci in neposredno vpliva na podjetje in njegovo uspešnost (Musek Lešnik 2008).

pri čemer prihajajo v ospredje **programi zvestobe**, kot zelo pomembno orodje za zbiranje podatkov o kupcih oziroma članih programa zvestobe. Zbrane demografske in socio-ekonomske podatke je tako mogoče združiti s podrobnimi podatki o posameznih opravljenih transakcijah (podatki o nakupih), s povratnimi informacijami (reklamacije, pritožbe, priporočila, pohvale ...) in z **zunanje zbranimi podatki** (raziskave zadovoljstva, življenjskega stila, osebnih interesov, preživljanje prostega časa, nakupne navade, nakupne namere ...). Združeni podatki na nivoju kupca, iz notranjih in zunanjih virov, so temeljni pogoj za proces **odkrivanje znanja v podatkih**.

Nezadovoljstvo kupcev je lahko tudi rezultat slabo načrtovanih, implementiranih ali celo odsotnosti informacijskih tehnologij in procesov, ki trgovcu omogočajo, da se prilagajajo potrebam, pričakovanjem in željam potrošnikov. Tukaj so trgovcu v veliko pomoč **orodja za podatkovno rudarjenje**, ki mu omogočajo razumevanje kupcev.

Orodja za podatkovno rudarjenje presegajo standardizirana poročila v okviru analize prodaje, saj omogočajo sistematično in avtomatsko modeliranje na ravni posameznega kupca izbranih segmentov, ob upoštevanju vseh razpoložljivih podatkov (demografskih; socioekonomskih; psihografskih; transakcijskih; podatki o pritožbah, pohvalah, željah, predlogih; podatki o stroških na kupca; s podatki državnih raziskovalnih ustanov ali iz komercialnih virov ...) kupcev. Najpomembnejše za trgovca je identificiranje, razumevanje, merjenje in izgradnja profila segmenta najbolj zvestih kupcev, analiza nakupne košarice in izgradnja modelov: model odziva kupcev na ukrepe pospeševanja prodaje, model ohranjanja/osipa kupcev, model tveganja, model dobičkonosnosti, model življenjske vrednosti kupca in model vezane prodaje.

Zbrani podatki in pridobljeno znanje v procesu odkrivanja znanja v podatkih, služi trgovcem kot pomembno orodje trženjskega komuniciranja. S prilagojeno ponudbo ciljnim segmentom kupcev in prilagojenimi sporočili, trgovec z doslednim izvajanjem **ciljanega trženja in etičnimi ravnanji**⁸⁷ ustvarja nujne pogoje za **zaupanje in zadovoljstvo** kupcev.

⁸⁷ V odnosu (trgovec-kupec) kjer ni občutka etičnosti, se ne more razviti zvestoba. Etičnost je potrebna na obeh straneh: (i.) neetično vedenje trgovca usodno odbije prej zvestega kupca ter (ii.) neetično ravnanje kupca (npr. kraja) usodno vpliva na njegovo zvestobo do trgovca. Pri tem sploh ni pomembno, ali so ravnanja, ki jih kupci zaznajo kot neetična, s strani trgovca legitimna ali ne (Musek Lešnik 2008, 39–40).

Zvestoba kupcev torej ni enodimenzionalna, temveč je mnogo bolj kompleksna. Je splet več prepletajočih dejavnikov, ki vplivajo na zadovoljstvo in zaupanje⁸⁸ – oba skupaj sta potreben pogoj za zvestobo.

Če dodatno v obzir vzamemo 10 novih potrošniških trendov za leto 2016 (predstavitev trendov je v PRILOGI F⁸⁹), ki jih je pripravil Euromonitor International (Daphne 2016) in za katere domnevajo, da bodo imeli prevladujoč vpliv na trgovce, je upravljanje s strategijami za povečevanje zvestobe kupcev s poudarkom na poznavanju in razumevanju kupcev, v letu 2016 še toliko bolj pomembno.

Menim, da v naslednjih petih letih ne bo več vprašanje »Podatkovno rudarjenje da ali ne?«, temveč bodo orodja, ki trgovcu omogočajo zbiranje podatkov o kupcih (npr. programi zvestobe) ter orodja, ki trgovcu omogočajo odkrivanje znanja v podatkih (orodja za podatkovno rudarjenje) osnova in nuja – to bodo imeli vsi večji trgovci. Uspešnost bo odvisna od:

- sposobnosti trgovca, da vzpostavi učinkovite strategije za upravljanje odnosov s kupci (sposobnost za premik v razumevanju programa zvestobe kot orodja za zvišanje dodatne vrednosti trgovca, k razumevanju programa zvestobe kot orodja za zvišanje dodatne vrednosti za kupca, preko katere se viša dodana vrednost trgovca);
- zmožnosti spremljanja in merjenja ne le transakcij, temveč celovite/vseživljenjske (360°) izkušnje na kupca;
- dobro poznavanje in razumevanje kupcev, ne samo na nivoju segmentov oziroma ciljnih skupin, temveč na nivoju posameznega kupca;
- zmožnosti poosebljanja nakupovalne košarice s pomočjo napovedne analitike;
- zmožnosti ponujanja individualiziranih nagrad;
- sposobnosti nagovarjanja pravih kupcev – prepoznati zveste kupce od »lažno« zvestih kupcev;
- zmožnosti integriranja pridobljenega znanja v procesu odkrivanja znanja v podatkih v osrednje strategije trženja, prodajnih politik, širjenja trgovskih blagovnih znamk, politike oblikovanja cen, urejanja prodajaln, upravljanja s sortimentom ...;

⁸⁸ Zaupanje je občutek varnosti in zanesljivosti, ki ga kupec začuti na osnovi predhodnih izkušenj in prepričanja, da je trgovec ustrezno zadovoljil njegove potrebe in želje. Zaupanje igra vlogo »lepila« v odnosu med kupcem in trgovcem (Musek Lešnik 2008, 68–71).

⁸⁹ Za bolj obsežen pregled potrošniških trendov za leto 2016 glej v Daphne (2016).

- zmožnosti razlikovanja od konkurence (po določenem atributu, ki ga kupci zaznajo kot dodano vrednost);
- zmožnost pridobivanja »zagovornikov« med kupci, ki bodo prispevali k pridobivanju in zvestobi novih kupcev;
- zmožnosti ciljanega trženja – še večjo prednost bodo imeli trgovci, ki bodo zmožni individualiziranega trženja, ki omogoča vsakemu kupcu ponuditi želen izdelek ali storitev, po najvišji zanj sprejemljivi ceni.

Večina trgovcev se bo v prihodnje morala soočiti s posodabljanjem oziroma učinkovitim izboljšanjem obstoječih programov zvestobe, če bodo želeli preživeti. Največja »rezerva« večine obstoječih programov zvestobe je v neizkoriščenosti potenciala, ki se skriva v zbranih (in največkrat neanaliziranih) podatkih. Z boljšo rabo teh podatkov, bi lahko že sedaj povečali možnosti za ohranjanje in povečevanja zvestobe kupcev in posledično poslovnega rezultata.

Sklepna misel: zvestoba kupcev neposredno in pomembno vpliva na rezultate in uspešnost trgovca. Najbolj pomemben pogoj za uresničevanje visoke zvestobe kupcev je znanje o kupcih, zato mora trgovec, ki stremi k uspešnosti, učinkovitosti, rasti in razvoju, jasno prepoznati in razumeti segment najbolj zvestih kupcev.

7 ZAKLJUČEK

»Znanje je pomembno. Toda še veliko pomembnejša je njegova koristna uporaba. Ta je odvisna od srca in uma človeka.«

Dalaj Lama

Namen magistrskega dela na osebnem nivoju, je osvojiti osnovno znanje iz odkrivanja znanja v podatkih do te mere, da bi obstoječe tehnike podatkovnega rudarjenja lahko uporabila in/ali prilagodila za reševanje problemov na poslovnem področju oziroma na lastni poklicni poti, kjer se srečujem s težkimi odločitvenimi problemi, pri katerih bi si lahko pomagala s tehnikami podatkovnega rudarjenja. Prav tako je namen seznaniti se z raziskovalnimi dosežki na tem področju – predvsem v poslovnem okolju trgovca s poudarkom na povečevanju zvestobe kupcev.

V času ko se trgovci soočajo: z vse zahtevnejšimi kupci, s hitro spreminjajočimi se potrebami, željami, hotenji in pričakovanji; z intenzivnim in globalnim konkuriranjem dobro utrjenih konkurentov; s hitrejšim vstopanjem novih izdelkov na trg; s poplavo informacij, oglasov, programov zvestobe ...; s cenovno tekmo in upadom zvestobe kupcev ...; s pomembnim vplivom uporabe interneta, mobilnih telefonov, socialnih omrežij (t.i. digitalizacija) ... – je učinkovito upravljanje z zadovoljstvom in zvestobo kupcev spretnost, s katero si zagotavljajo konkurenčno prednost, boljši poslovni rezultat in ne malokrat tudi obstoj.

Trgovec si lahko gradi zvestobo kupcev na več načinov: skrb za osnovne higienike v trgovini, s kakovostjo izdelkov/storitev, z razvojem lastnih (trgovskih) blagovnih znamk, skrb za zalogo akcijskih artiklov, s primernimi odzivi na kritične dogodke, s skrbjo za odnose s kupci, s pozitivno podobo trgovca, s poštenimi cenovnimi strategijami, z etičnim poslovnim ravnanjem, s programi zvestobe kupcev, z razumevanjem kupcev (z odkrivanjem znanja o kupcih v podatkih – internih in zunanjih), z doslednim in sistematičnim izvajanjem strategije osredotočenosti na kupca ... Zvestoba kupca je rezultat sinergije naštetih dejavnikov, ki skupaj z zaupanjem in zadovoljstvom kupca vplivajo na to, ali bo določen kupec postal in ostal zvest trgovcu ali ne.

Vendar za dolgoročno zagotavljanje zvestobe kupcev, mora biti strategija trgovca »osredotočenost na kupca«, z zapisanimi cilji:

- Končni cilj je zvestoba kupcev (in ne zadovoljstvo, kot je to zmotno prepričanje večine trgovcev, samo zadovoljstvo ni zadostni pogoj za zvestobo).
- Zagotavljanje zvestobe kupcev je investicija (investicija v znanje: v proces za odpiranje znanja, v strokovne ljudi, v tehnologijo, v kvalitetne izdelke in storitve ...).
- V proces zagotavljanja zvestobe morajo biti vključeni vsi zaposleni.

Navsezadnje je strategija osredotočenosti na kupca in program zvestobe, danes ne samo stvar mode, ampak pri trgovcih že stvar nuje. Pri čemer prihodnost ne pripada programom zvestobe, ki temeljijo na cenovnih akcijah (ki »kupujejo« njihovo zvestobo z različnimi popusti, ugodnostmi, sistemi zbiranja »točk« ...), temveč programom zvestobe »dodane vrednosti«. To pomeni, da bodo v prihodnje imeli najboljše možnosti trgovci, ki lahko kupcem ponudijo več kot le popuste. Največja prednost programov zvestobe (v prihodnjih petih letih) je ogromna količina podatkov, ki omogoča odkrivanje znanja o kupcih in individualiziranje ponudbe njihovim željam in potrebam, na nivoju posameznega kupca.

Pri vseh treh največjih trgovcih (na slovenskem trgu) ugotavljam velik razkorak med obstoječim stanjem in strategijo, ki jo razglašajo. Vse večja cenovna občutljivost na eni strani in nižji nivo zvestobe kupcev na drugi, sta rezultirala v pravo malo cenovno vojno. Kupci smo tako danes iz vseh treh strani bombardirani s ponudbami primerljive kakovosti in s podobnimi (velikokrat celo z enakimi) sporočili: 10 % (ali 11 %) popust na vrednost celotnega nakupa, 25 % (ali 20 %) popust na izbrani izdelek, kupon v obliki srečke kot popust (20 % do 90 %) na vrednost celotnega nakupa ali izbranega izdelka, vračanje dobroimetja na kartico, kuponi v obliki popustov na blagovne skupine ...

Šele takrat ko trgovec zna in zmore dosledno uresničevati strategijo osredotočenosti na kupca in pravega programa zvestobe, lahko zagotovi kupcem »dodano vrednost«, zaradi katere se bodo začeli vračati in ne bodo odhajali drugam, kadar bodo naleteli na »vabo« konkurence. Da pa lahko ponudijo več, torej dodano vrednost, je osnovni predpogoj poznavanje kupcev.

Informacije iz podatkovnih baz programa zvestobe so lahko uporabljene za izboljšanje komunikacijskega trženja in za ugotavljanje potreb ter želja različnih segmentov kupcev – za pridobivanje novih in zadrževanje najbolj zvestih kupcev ter za povečevanje vrednosti in

zvestobe obstoječih kupcev, kar trgovcu omogoča sposobnost prilagoditve ponudbe posameznemu segmentu in po potrebi posameznemu kupcu. Izkoriščanje potenciala, ki ga nudi proces odkrivanja znanja v podatkih, omogoča trgovcu ohranjanje in povečevanje konkurenčne prednosti.

Uporabo procesa odkrivanja znanja v podatkih – z uporabo metod podatkovnega rudarjenja, na primeru programa zvestobe Tuš kluba trgovca Engrotuš d.d. (krajše Tuš), sem predstavila v empiričnem delu magistrske naloge. Za Tuš je ključnega pomena, da zna prepoznati oziroma identificirati najbolj zveste kupce skupine Tuš (trgovinska in drogerijska dejavnost) ter najbolj zveste kupce lastne blagovne znamke. Rezultati prekrivanja obeh taktičnih segmentov nakazujejo, da zvestobo skupini Tuš v polovici določa zvestoba trgovčevi lastni blagovni znamki, polovico pa določajo drugi dejavniki (demografija, kakovost izdelkov, cenovne strategije, odnos do kupcev ...). Vendar sama identifikacija oziroma izgradnja segmenta ni dovolj, potrebno je poznavanje profila obeh segmentov, da lahko trgovec prilagodi aktivnosti ciljanega trženja, s ciljem ohranjanja in povečevanja zvestobe.

Profil »TOP_ZVESTI_TUŠ«: *TK člani ženskega spola, v starosti 45 do 65 let in nikakor ne mlajši od 30 let ter iz Obalno-kraške, Savinjske in Osrednjeslovenske regije.*

Profil »TOP_LBZ«: *TK člani ženskega spola, v starosti 45 do 65 let ter iz Koroške in Obalno-kraške regije.*

Profila obeh taktičnih segmentov sta si dokaj podobna, z razliko, da je v TOP_LBZ nekoliko več moških, več mlajših oziroma pod 30 let ter več iz Koroške regije. To je zelo vzpodbudna in uporabna informacija za trgovca Tuš pri oblikovanju strategije lastne blagovne znamke, pri trženjskih aktivnostih za pospeševanje prodaje in informiranja kupcev o lastni blagovni znamki ter za gradnjo in pospeševanje zvestobe lastni blagovni znamki in trgovini oziroma skupini Tuš – pri populaciji, kjer trenutno Tuš ni najbolj močan. Eden od zaključkov magistrskega dela je, da ima Tuš velik potencial povečevanja zvestobe kupcev skupini Tuš s povečanjem naporov pri gradnji strategije in zvestobe lastne blagovne znamke.

Poznavanje profila najbolj zvestih kupcev samo po sebi ni dovolj. Pridobljeno znanje je potrebno uporabiti v praksi, v aktivnostih ciljanega trženja. Na tej točki, so trgovcu lahko v veliko pomoč rezultati analize nakupne košarice oziroma rezultati učenja povezovalnih pravil. Na novo pridobljeno znanje mu omogoča, da aktivnosti ciljanega trženja nadgradi tako, da

segmentu kupcev ponudi artikle, ki jih kupci pogosto kupujejo skupaj. Rezultati analize nakupne košarice služijo tudi kot predlogi za ponujanje novih in nadgradnjo obstoječih artiklov ter predvsem ponujajo boljše razumevanje nakupnih navad kupcev. Dejanska uporaba pridobljenega znanja pri trženjskih aktivnostih ima za trgovca naslednje posledice: povečevanje prodaje, povečevanje profita, zmanjšanje stroškov ter povečevanje zvestobe kupcev.

Splošni zaključki na osnovi empiričnega dela magistrske naloge so naslednji:

- V vsaki podatkovni bazi trgovca je povezovalnih pravil ogromno, vendar niso vsa zanimiva in dovolj pogosta za uporabo pridobljenega znanja v aktivnostih ciljanega trženja. Zato je potrebno algoritem, ki ustvarja pravila, omejiti z minimalno mejo podpore in minimalno mejo zaupanja tako, da so pravila še vedno dovolj pogosta in hkrati dovolj zanimiva oziroma uporabna za aktivnosti ciljanega trženja. Pri čemer ne morem podati splošnega priporočila, kakšna je optimalna meja, za obravnavano problemsko področje, ta je namreč odvisna od razpršenosti podatkov oziroma od taksonomije blagovnih skupin, od velikosti podatkovne baze in od razpoložljivih sredstev za aktivnosti ciljanega trženja. Z večanjem razpršenosti podatkov eksponentno pada število ustvarjenih pravil. Tako je z večanjem razpršenosti podatkov potrebno zmanjševati mejo podpore in zaupanja, pri čemer je na strani uporabnika, kako bo omejil algoritem. Uporabnik je dodatno omejen s tehničnimi zmogljivostmi, ki dodatno vplivajo na izbiro ustreznega pristopa k reševanju obravnavanega problema.
- Največji potencial analize nakupne košarice je v nadgradnji enonivojskih povezovalnih pravil z večdimenzionalnimi povezovalnimi pravili. Nakupni košarici dodamo demografske podatke o kupcu oziroma katere koli podatke (katere trgovec shranjuje), ki imajo veliko informativno vrednost za povečevanje odziva na aktivnosti ciljanega trženja ter zvestobe kupcev (npr. podatki iz anket zadovoljstva). Večdimenzionalna povezovalna pravila so posebej uporabna v primerih: kadar nas zanimajo zelo specifična pravila (nizka podpora, visoko zaupanje); za aktivnosti ciljanega trženja na zelo specifične ter majhne segmente ali kadar imamo omejena sredstva za aktivnosti ciljanega trženja; za poglobljeno razumevanje nakupnih navad ter za povečevanje odziva na aktivnosti ciljanega trženja (npr. odziva na direktno pošto).

- Prava vrednost analize povezovalnih pravil se pokaže, ko je trgovec sposoben odkriti skrite, komaj opazne vzorce oziroma povezave med izdelki (ki jih sam ni zmožen določiti intuitivno), kar mu omogoča prav odkrivanje znanja v podatkih. Dodatna ugotovitev je, da se tudi med najbolj pogostimi povezovalnimi pravili (oziroma pravili z največjo mejo podpore) v podatkovni množici skriva novo znanje, ki se ga brez analize povezovalnih pravil (oziroma intuitivno), ne da odkriti.
- Splošna ugotovitev, ki izhaja iz vsebinske nadgradnje povezovalnih pravil: kadar je število storniranih računov manjše od 1 %, se jih lahko pri analizi povezovalnih pravil zanemari, brez da bi pri tem izgubili pomembne vsebinske informacije (oziroma jih ni potrebno izločati v procesu priprave podatkov).
- Rezultati celotnega procesa odkrivanja znanja v podatkih ter eksperimentiranja z različnimi tehnikami podatkovnega rudarjenja, so informacije z veliko potencialno vrednostjo za trgovca – za povečevanje prodaje, povečevanje profita, zmanjševanje stroškov ter povečevanje zvestobe kupcev.

Podatkovno rudarjenje je nedvomno močno orodje za povečevanje zvestobe kupcev, vendar se mora trgovec zavedati, da sama tehnologija ne ustvarja zvestih kupcev – ne more nadomestiti dobrega načrtovanja, jasnih ciljev in načrtnega razvijanja odnosov s kupci (krajše človeka), ki so nujni pogoj zvestobe. Podatkovno rudarjenje, v sklopu celovitega procesa odkrivanja znanj v podatkih, omogoča načrtno spodbujanje zvestobe kupcev, vendar hkrati zahteva tudi veliko znanja in spretnosti zaposlenih. Zato je ključno, da trgovec od samega začetka načrtovanja tehnologijo razume kot nujno podporo poslovni strategiji, ne pa kot zadostni dejavnik.

Izzivi za nadaljnje raziskovanje

Za povečevanje zadovoljstva in zvestobe kupcev ni dovolj samo poznavanje oziroma analiziranje notranjih (internih) zbranih podatkov, temveč je potrebno te podatke združiti (če se le-da na nivoju kupca⁹⁰) z zunanji podatki (raziskave zadovoljstva, preživljanja prostega časa, življenjskega stila, nakupnih namer, stopnje etnocentrizma ...) in si tako pridobiti širšo sliko. V prihodnje bi si tako želela ugotavljati vpliv splošnega zadovoljstva članov programa

⁹⁰ Proces združitve transakcijskih in anketnih podatkov, pri čemer se obe vrsti podatkov nedvoumno pripišejo posameznemu kupcu, lahko trgovec izvede na več načinov. V okviru magistrskega dela se omejujem na uporabo kartic zvestobe, izdanih v okviru programov zvestobe.

zvestobe s trgovcem (zadovoljstvo s ponudbo, s prodajnim osebjem, s čistočo in ureditvijo same trgovine ...). Trгоvec lahko podatke o zadovoljstvu pridobi sam (s telefonskim anketiranjem iz oddelka odnosov s kupci, z anketiranjem na spletu ...) ali pa s pomočjo zunanje agencije – v obeh primerih je zelo pomembno, da se poveže enoznačna identifikacijska številka člana programa zvestobe in enoznačna identifikacijska številka anketnega vprašalnika.

Sama sem mnenja, da je vsekakor boljše, da trгоvec raziskavo izvede sam (z notranjimi viri), in sicer na način kombinacije anketnega vprašalnika in skupinskega intervjuja, skozi t.i. svetovalna združenja kupcev (angl. »*customer advisory board*«). Trгоvec povabi slučajni vzorec članov programa zvestobe (po določenih segmentih) v svoje prostore, kjer izvede skupinski intervju v obliki diskusije (skupina se pogovarja o določenih temah, ki so predhodno definirane s strani trgovca: npr. skupino se sprašuje, kako vidijo njih v odnosu do konkurenčnega trgovca, kakšno ponudbo še pogrešajo, kaj jih najbolj zmoti v trgovini ...) ter na koncu jih naprosi za izpolnitev anketnega vprašalnika. Tako pridobljeno znanje lahko trгоvec uporabi za povečevanje zvestobe kupcev in vsekakor predstavlja to znanje pomembno konkurenčno prednost glede na konkurenco, ki tega znanja nima.

Za zaključek podajam še sklepno misel: *»Zvestoba ne more biti samo cilj. Zvestoba je priložnost trgovca za oblikovanje svoje lastne ubranljive in edinstvene konkurenčne prednosti. Zvestoba kupcev pomeni več kot le ponovljivost nakupov, pomeni več kot zgolj le preferiranje lastne blagovne znamke trgovca, pomeni njihovo predanost.«*

8 LITERATURA

1. Abbott, Julie, Merlin Stone in Francis Buttle. 2001. Customer relationship management in practice—a qualitative study. *The Journal of Database Marketing* 9 (1): 24–34.
2. *Adria*. Dostopno prek: <https://www.adria.si/> (14. januar 2016).
3. Agrawal, Rakesh, Tomasz Imieliński in Arun Swami. 1993. Mining association rules between sets of items in large databases. *ACM SIGMOD Record* 22 (2): 207–216.
4. Agrawal, Rakesh in Ramakrishnan Srikant. 1994. Fast algorithms for mining association rules. *Proc. 20th int. conf. very large data bases, VLDB* 1215: 487–499.
5. Albrecht, Karl. 1995. *Delivering customer value: it's everyone's job*. Portland, Oregon: Productivity Press.
6. Ashley, Christy, Erin A. Gillespie in Stephanie M. Noble. 2016. The effect of loyalty program fees on program perceptions and engagement. *Journal of Business Research* 69 (2): 964–973.
7. Avdičauševič, Enis, Mitja Lenič in Peter Kokol. 2002. Multimetodno odkrivanje asociativnih pravil. *Zbornik enajste mednarodne Elektrotehniške in računalniške konference ERK 2002*, 23.–25. september 2002; Portorož, Slovenija; Ljubljana; 2002; Zv. B; 35–38.
8. Bagdonienė, Liudmila in Rasa Jakštaitė. 2007. Estimation of Loyalty Programmes from Customers' Point of View: Cases of Three Retail Store Chains. *Engineering Economics* 55 (5): 51–58.
9. Berry, Michael J. in Gordon Linoff. 1997. *Data Mining Techniques for Marketing, Sales and Customer Relationship Management*. Wiley Computer Publishing, John Wiley & Sons.
10. --- 2000. Mastering Data Mining: the art and science of customer relationship management. *Industrial Management & Data Systems* 100 (5): 245–246.
11. Berson, Alex in Stephen J. Smith. 1997. *Data Warehousing, Data Mining & OLAP*. McGraw-Hill, Inc..
12. Bramer, Max. 2007. *Principles of data mining*. London: Springer.
13. Brumen, Boštjan. 2004. *Empirični postopek ocenitve algoritmov za klasifikacijo*. Maribor: Doktorska disertacija, FRI.

14. Chapman, Pete, Julian Clinton, Randy Kerber, Thomas Khabaza, Thomas Reinartz, Colin Shearer in Rudiger Wirth. 2000. *CRISP-DM 1.0 Step-by-step data mining guide*. CRISP-DM consortium. Dostopno prek: <http://www.crisp-dm.org> (19. december 2015).
15. Chen, Yen-Liang, Kwei Tang, Ren-Jie Shen in Ya-Han Hu. 2005. Market basket analysis in a multiple store environment. *Decision support systems* 40 (2): 339–354.
16. CMS International. 2014. *Kaj pripravlja EU na področju varstva osebnih podatkov?* Dostopno prek: <http://www.cms-rrh.com/si-Newsletter-2014-09-Kaj-pripravlja-EU-na-podrocju-varstva-osebni-podatkov-10-11-2014> (14. januar 2016).
17. Cuneo, Andres, Sandra J. Milberg, Jose Miguel Benavente in Javier Palacios-Fenech. 2015. The Growth of Private Label Brands: A Worldwide Phenomenon?. *Journal of International Marketing* 23 (1): 72–90.
18. Damjan, Janez in Stane Možina. 1998. *Obnašanje potrošnikov*. Ljubljana: Univerza v Ljubljani, Ekonomska fakulteta.
19. Damjan, Janez in Irena Vida. 1997. Poznavanje blagovnih znamk in etnocentrizem porabnikov kot dejavnika nakupnega obnašanja. *Akademija MM: Slovenska znanstvena revija za trženje* (1): 21–28. Dostopno prek: <http://www.dlib.si/details/URN:NBN:SI:DOC-L8SRBV2G> (19. december 2015).
20. Daphne, Kasriel-Alexander. 2016. *Top 10 Global Consumer Trends for 2016*. Euromonitor International, 2016.
21. Dash, Priyaranjan in Suryakanta Mishra. 2010. Developing RFM model for customer segmentation in retail Industry. *International Journal of Marketing & Human Resource Management (IJMHRM)* 1 (1): 58–69. Dostopno prek: http://papers.ssrn.com/sol3/papers.cfm?abstract_id=2190800 (9. januar 2016).
22. Demšar, Janez. 2000. Asociativna pravila. *Monitor* 10 (3): 130–133.
23. Dong, Guozhu in Jinyan Li. 1998. Interestingness of discovered association rules in terms of neighborhood-based unexpectedness. *Research and Development in Knowledge Discovery and Data Mining*, Springer Berlin Heidelberg: 72–86.
24. Dumitru, Valentin-Florentin, Gabriel Jinga, Florin Mihai in Aurelia Ștefănescu. 2015. Innovative information technologies and their impact on the performance of the entities which activate in the retail industry. *Amfiteatru Economic* 17 (39): 520–535.
25. *Engrotuš*. Dostopno prek: <http://www.tus.si/> (25. januar 2016).
26. Euromonitor International. 2014. Odnos do zasebnih oziroma trgovskih blagovnih znamk. *InStore* 3 (27) (julij–avgust 2014).

27. European Commission. 2015. *Agreement on Commission`s EU data protection reform will boost Digital Single Market*. Dostopno prek: http://europa.eu/rapid/press-release_IP-15-6321_en.htm (15. december 2015).
28. Fayyad, Usama M., Gregory Piatetsky-Shapiro, Padhraic Smyth in Ramasamy Uthurusamy., ur. 1996. *Advances in knowledge discovery and data mining*. London: The MIT Press.
29. Fayyad, Usama M., Gregory Piatetsky-Shapiro in Padhraic Smyth. 1996a. From data mining to knowledge Discovery in Databases. *AI Magazine* 17 (3): 37–54. Dostopno prek: <http://www.csd.uwo.ca/faculty/ling/cs435/fayyad.pdf>. (19. december 2015).
30. --- 1996b. The KDD process for extracting useful knowledge from volumes of data. *Communications of the ACM* 39 (11): 27–34. Dostopno prek: <http://shawndra.pbworks.com/f/The%20KDD%20process%20for%20extracting%20useful%20knowledge%20from%20volumes%20of%20data.pdf>. (9. januar 2016).
31. Fayyad, Usama M., Georges G. Grinstein in Andreas Wierse. 2002. *Information vizualization in data mining and knowledge discovery*. San Francisco: Morgan Kaufmann Publisher.
32. Ferligoj, Anuška. 1989. Razvrščanje v skupine: teorija in uporaba v družboslovju. *Metodološki zvezki* (4). Ljubljana: Raziskovalni inštitut, Fakulteta za sociologijo, politične vede in novinarstvo.
33. Fowler, Danielle, Dennis Pitta in Richard C. Leventhal. 2013. Technological advancements and social challenges for one-to-one marketing. *Journal of Consumer Marketing* 30 (6): 509–516.
34. Geffroy, K. Edgar. 1996. *Kupec – nepotrebno zlo: klientstvo spodrina trženje in vnaša revolucijo v prodajo*. Ljubljana: Center za tehnološko usposabljanje.
35. Geng, Liqiang in Howard J. Hamilton. 2006. Interestingness measures for data mining: A survey. *ACM Computing Surveys (CSUR)* 38 (3): 1–32.
36. Gregorčič, Simon. 2004. Projekt program zvestobe strank. *Revija za projektni management* 7 (4): 29–41.
37. Griffin, Jill. 2002. *Costumer Loyalty: how to earn it, how to keep it*. San Francisco, CA: Jossey-Bass, A Wiley Imprint.
38. Grobelnik, Marko, Maja Škrjanc in Darko Zupanič. 2003. Analysis of Slovenian Media Space. *Data Mining and Decision Support: Integration and Collaboration*, ur. Mladenić, D. in drugi, 133–141. Springer US.

39. Ho, Chien-Ta Bruce, Jong-Min Denis Yang in Chi-Sheng Victor Hung. 2015. The Factors of Information System Success: An Example of Customer Relationship Management Implementation in Food & Beverage Industry. *International Journal of e-Education, e-Business, e-Management and e-Learning* 5 (3): 114–128.
40. Hughes, Arthur M.. 2006. *Strategic database marketing: the masterplan for starting and managing a profitable, customer-based marketing program*. McGraw-Hill.
41. Jai, Tun-Min Catherine, Leslie Davis Burns in Nancy J. King. 2013. The effect of behavioral tracking practices on consumers' shopping evaluations and repurchase intention toward trusted online retailers. *Computers in Human Behavior* 29 (3): 901–909.
42. Jai, Tun-Min Catherine in Nancy J. King. 2016. Privacy versus reward: Do loyalty programs increase consumers' willingness to share personal information with third-party advertisers and data brokers?. *Journal of Retailing and Consumer Services* 28: 296–303.
43. Jentzsch, Nicola, Geza Sapi in Irina Suleymanova. 2013. Targeted pricing and customer data sharing among rivals. *International Journal of Industrial Organization* 31 (2): 131–144.
44. Kavšek, Branko. 2004. *Odkrivanje podskupin z uporabo algoritmov za učenje pravil*. Ljubljana: Doktorska disertacija, FRI.
45. Keiningham, Timothy L., Terry G. Vavra, Lerzan Aksoy in Henri Wallard. 2005. *Loyalty myths: hyped strategies that will put you out of business – and proven tactics that rally work*. John Wiley and Sons, Inc., Hoboken, New Jersey.
46. Klemettinen, Mika, Heikki Mannila, Pirjo Ronkainen, Hannu Toivonen in A. Inkeri Verkamo. 1994. Finding interesting rules from large sets of discovered association rules. *Proceedings of the third international conference on Information and knowledge management, ACM*, 401–407.
47. Khodakarami, Farnoosh in Yolande E. Chan. 2014. Exploring the role of customer relationship management (CRM) systems in customer knowledge creation. *Information & Management* 51 (1): 27–42.
48. Kononenko, Igor. 2005. *Strojno učenje*. Ljubljana: Fakulteta za računalništvo in informatiko.
49. Kononenko, Igor in Matjaž Kukar. 2007. *Machine Learning and Data Mining: Introduction to Principles and Algorithms*. Horwood Publishing.

50. Koschate-Fischer, Nicole, Johannes Cramer and Wayne D. Hoyer. 2014. Moderating effects of the relationship between private label share and store loyalty. *Journal of Marketing* 78 (2): 69–82.
51. Košmelj, Katarina. 2001. *Uporabna statistika*. Ljubljana: Biotehniška fakulteta Univerze v Ljubljani.
52. Kotler, Philip. 2004. *Management trženja*. Ljubljana: GV založba.
53. Kotler, Philip in Kevin L. Keller. 2006. *Marketing management*. Upper Saddle River (New Jersey), Pearson Education, Prentice Hall.
54. Kralj, Petra. 2007a. *Association rules*. Dostopno prek: <http://kt.ijs.si/PetraKralj/DM-2007/AssociationRules.pdf>. (9. januar 2016).
55. --- 2007b. *Naive Bayes Classifier*. Dostopno prek: <http://kt.ijs.si/PetraKralj/DM-2007/NaiveBayes.pdf>. (9. januar 2016).
56. Kukovec, Nataša. 2013. *Marketinško strateško odločanje v zvezi z zadovoljstvom odjemalcev*. Maribor: Magistrsko delo, Ekonomsko-poslovna fakulteta.
57. Kumar, Venkat in W. J. Reinartz. 2006. *Customer relationship management: a databased approach*. John Wiley & Sons, Inc..
58. Kushwaha, Tarun. 2014. An Exploratory Study of Consumer's Perception about Relational Benefits in Retailing. *Procedia-Social and Behavioral Sciences* 133: 438–446.
59. Horvat, Igor, Jože Rovani in Anuška Ferligoj. 1998. Segmentation of retail bank market. *Delovni zvezki* (78). Ljubljana: Raziskovalni center Ekonomske fakultete.
60. Informacijski pooblaščenec. 2004. *Odločbe in mnenja – varstvo osebnih podatkov: pristopnica za pridobitev P. kartice, segmentirano trženje*. Dostopno prek: https://www.ip-rs.si/varstvo-osebnih-podatkov/iskalnik-po-odlocbah-immnenjih/odlocbe-in-mnenja-varstvo-osebnih-podatkov/?tx_jzvopdecisions_pi1%5BshowUid%5D=2332&cHash=2aa8eda65e50c0d338c7b93280722551 (9. januar 2016).
61. Lavrač, Nada. 2007. *Predavanje »Data Mining and Knowledge Discovery«*. Ljubljana: Mednarodna podiplomska šola Jožefa Štefana.
62. Leban, Gregor. 2007. *Vizualizacija podatkov s strojnimi učenjem*. Doktorska disertacija, Univerza v Ljubljani. Ljubljana: Fakulteta za računalništvo in informatiko.
63. Lenca, Philippe, Patrick Meyer, Benoit Vaillant in Stéphane Lallich. 2008. On selecting interestingness measures for association rules: User oriented description and multiple criteria decision aid. *European journal of operational research* 184 (2): 610–626.

64. Lent, Brian, Arun Swami in Jennifer Widom. 1997. Clustering association rules. *Data Engineering, 1997. Proceedings. 13th International Conference on. IEEE*, 220–231.
65. Levy, Michael in Barton A. Weitz. 2012. *Retailing management*. Irwin: McGraw-Hill, Boston.
66. Li, Jiuyong. 2006. On optimal rule discovery. *Knowledge and Data Engineering, IEEE Transactions on* 18 (4): 460–471.
67. Liu, Bing, Wynne Hsu, Shu Chen in Yiming Ma. 2000. Analyzing the subjective interestingness of association rules. *Intelligent Systems and their Applications, IEEE* 15 (5): 47–55.
68. Liu, Yuping. 2007. The long-term impact of loyalty programs on consumer purchase behaviour and loyalty. *Journal of Marketing* 71 (4): 19–35.
69. Martos-Partal, Mercedes in Óscar González-Benito. 2013. Studying motivations of store-loyal buyers across alternative measures of behavioural loyalty. *European Management Journal* 31 (4): 348–358.
70. Marzo-Navarro, Mercedes, Marta Pedraja-Iglesias in Ma Pilar Rivera-Torres. 2004. The benefits of relationship marketing for the consumer and for the fashion retailers. *Journal of Fashion Marketing and Management: An International Journal* 8 (4): 425–436.
71. McCarty, John A. in Manoj Hastak. 2007. Segmentation approaches in data-mining: a comparison of RFM, CHAID, and logistic regression. *Journal of Business Research* 60 (6): 656–662. Dostopno prek: https://www.researchgate.net/profile/Manoj_Hastak/publication/222435764_Segmentation_approaches_in_datamining_A_comparison_of_RFM_CHAID_and_logistic_regression/links/553031d00cf2f2a588ab0a21.pdf. (19. december 2015).
72. McCorkell, Graeme. 1999. *Direct and database marketing*. London: The Institute of Direct Marketing, Kogan Page.
73. McGarry, Ken. 2005. A survey of interestingness measures for knowledge discovery. *The knowledge engineering review* 20 (1): 39–61.
74. Meyer-Waarden, Lars. 2015. Effects of loyalty program rewards on store loyalty. *Journal of Retailing and Consumer Services* 24: 22–32.
75. Ministrstvo za pravosodje Republike Slovenije. 2015. *Pomemben korak k novi ureditvi varstva osebnih podatkov v EU*, 21. december. Dostopno prek: http://www.mp.gov.si/si/novinarsko_sredisce/novica/article/1328/7207/7117df0b9aef362b9645ad055775e089/ (25. januar 2016).

76. Mladenić, Dunja, Nada Lavrač, Marko Bohanec in Steve Moyle, ur. 2003. *Data Mining and Decision Support: Integration and Collaboration*. Kluwer.
77. Mlakar, Ana. 2008. *Razvoj projekta Tuš Klub*. Diplomaska naloga. Maribor: Višja strokovna šola Maribor, DOBA, Evropsko poslovno izobraževalno središče.
78. Možina, Stane, Mitja Tavčar in Vinko Zupančič. 2012. *Vedenje potrošnikov in tržnikov*. Maribor: Založba Pivec.
79. Musek Lešnik, Kristijan. 2007. *Zvestoba potrošnikov: psihološki dejavniki vedenja in zvestobe potrošnikov*. Ljubljana, IPSOS.
80. --- 2008. *Od zadovoljstva potrošnikov do programov zvestobe: nekateri psihološki dejavniki zadovoljstva in zvestobe potrošnikov in njihova integriranost v programe za sistematično spodbujanje zadovoljstva, zvestobe in zelenega vedenja potrošnikov*. Koper: Univerza na Primorskem, Fakulteta za management Koper.
81. Naghiu, N. O.. 2011. The psychological implications behind the marketing strategies that aim to predetermine costumers's behavior. *Review of Management & Economic Engineering* 10 (2): 127–135.
82. Nguyen, Bang in Philipp Klaus. 2013. Retail fairness: Exploring consumer perceptions of fairness towards retailers' marketing tactics. *Journal of Retailing and Consumer Services* 20 (3): 311–324.
83. Nies, Salome in Martin Natter. 2012. Does private label quality influence consumers' decision on where to shop?. *Psychology & Marketing* 29 (4): 279–292.
84. Ofner, Martin H., Boris Otto in Hubert Österle. 2012. Integrating a data quality perspective into business process management. *Business Process Management Journal* 18 (6): 1036–1067.
85. Ograjenšek, Irena. 2002a. Analiza podatkov kupcev: izzivi obvladovanja kakovosti storitev. *Vključevanje in povezovanje statistike v informacijsko družbo*. Ljubljana: SURS.
86. --- 2002b. Program zvestobe [1.-3. del.]. *Profesionalna prodaja* 7 (2): 16–17, 30–31, 32–33.
87. --- 2003. Use of customer data analysis in continuous quality improvement of service processes. *Proceedings of the Seventh Young Statisticians Meeting* (Ur. A. Mrvar). Fakulteta za družbene vede, Univerza v Ljubljani, 51–69. Dostopno prek: <http://www.stat-d.si/mz/mz21/ograjen.pdf>. (19. januar 2016).
88. Ograjenšek, Irena in Vesna Žabkar. 2005. Segmenting Members of a Retailer Loyalty Programme Using Personnel-Related Service Quality Dimensions. *Delovni zvezki*,

- Raziskovalni center Ekonomske fakultete (173). Dostopno prek: http://www.google.si/url?sa=t&rct=j&q=&esrc=s&source=web&cd=2&ved=0ahUKEw ijo6sx6vKAhUH2xoKHeyiBK4QFgghMAE&url=http%3A%2F%2Fwebv1ef.ef.uni-lj.si%2Fdokumenti%2Fwp%2FOgr_Zab_Working%2520Paper_submitted.doc&usg=AFQjCNEc9Oyv0zBdvoaZdetCfj2gpEHycw. (19. januar 2016).
89. --- 2010. Enhancing the value of survey data on customer satisfaction in the framework of a customer loyalty programme: case of a Slovenian retailer. *Quality Technology & Quantitative Management* 7 (2): 133–147. Dostopno prek: http://web.it.nctu.edu.tw/~qtqm/qtqmpapers/2010V7N2/2010V7N2_F3.pdf. (19. januar 2016).
 90. Pitta, Dennis A.. 1998. Marketing one-to-one and its dependence on knowledge discovery in databases. *Journal of consumer marketing* 15 (5): 468–480.
 91. Pivk, Aleksander. 2001. *Rudarjenje podatkov (Data Mining)*. Dostopno prek: <http://ai.ijs.si/Mezi/pedagosko/rudPod.pdf>. (19. januar 2016).
 92. Pleshko, Larry P. in Richard A. Heiens. 2015. Customer satisfaction and loyalty in the Kuwaiti retail services market: why are satisfied buyers not always loyal buyers?. *The International Review of Retail, Distribution and Consumer Research* 25 (1): 55–71.
 93. Podgorelec, Vili. 2001. *Oblikovanje inteligentnih sistemov in odkrivanja znanja z avtomatskim programiranjem*. Maribor: Doktorska disertacija, FRI.
 94. Potočnik, Vekoslav. 2001. *Trženje v trgovini*. Ljubljana: GV Založba.
 95. Pyle, Dorian. 1999. *Data preparation for data mining*. San Francisco, USA: Morgan Kaufmann Publisher.
 96. Raeder, Troy in Nitesh V. Chawla. 2011. Market basket analysis with networks. *Social network analysis and mining* 1 (2): 97–113.
 97. Radder, L., M. Van Eyk in C. Swiegelaar. 2015. Levels of customer loyalty and perceptions of loyalty programme benefits: A South African retail example. *The Retail and Marketing Review* 11 (1): 92–105.
 98. Reid, Andrea in Miriam Catterall. 2005. Invisible data quality issues in a CRM implementation. *Journal of Database Marketing & Customer Strategy Management* 12: 305–314.
 99. Renko, Sanda in Mirna Družijanić. 2014. Perceived usefulness of innovative technology in retailing: Consumers' and retailers' point of view. *Journal of Retailing and Consumer Services* 21 (5): 836–843.

100. *Resolucija o nacionalnem programu varstva potrošnikov 2006-2010 (ReNPVP)*. Ur. l. RS 114/2005 (29. november 2005).
101. Riggins, Frederick J. in Samuel Fosso Wamba. 2015. Research Directions on the Adoption, Usage, and Impact of the Internet of Things through the Use of Big Data Analytics. *The 48 Hawaii International Conferences on System Sciences (HICSS)*, 5.–8. januar 2015, Kauai, Hawaii, USA, 1531–1540.
102. Robinson, Duncan. 2015. EU agresse strict new regime on data protection. *Financial Times*, 15. december. Dostopno prek: <http://www.ft.com/intl/cms/s/0/c3cd3194-a36e-11e5-bc70-7ff6d4fd203a.html#axzz3uQpFWOEo> (25. januar 2016).
103. Sällberg, H. (2010). *Customer Rewards Programs: Designing Incentives for Repeated Purchase*. Lambert Academic Publishing.
104. Scott, M. (2015). Europe Approves Tough New Data Protection Rules. *The New York Times*, 15. december. Dostopno prek: http://www.nytimes.com/2015/12/16/technology/eu-data-privacy.html?_r=1 (25. januar 2016).
105. Seenivasan, Satheesh, K. Sudhir in Debabrata Talukdar. 2015. Do Store Brands Aid Store Loyalty?. *Management Science*.
106. Seng, Jia-Lang in T. C. Chen. 2010. An analytic approach to select data mining for business decision. *Expert Systems with Applications* 37 (12): 8042–8057.
107. Sfiligoj, Nada. 2003. Vplivi marketinga na vedenje potrošnikov in njihove nakupne odločitve. *Akademija MM: Slovenska znanstvena revija za trženje* 6 (10): 75–80.
108. Sharp, Byron in Anne Sharp. 1997. Loyalty programs and their impact on repeat-purchase loyalty patterns. *International Journal of Research and Marketing* 14 (5): 473–486. Dostopno prek: <https://byronsharp.files.wordpress.com./2008/03/4025loyaltyprogs.pdf>. (9. december 2015).
109. Sheth, Jagdish N., Nirmal K. Sethia in Shanthi Srinivas. 2011. Mindful consumption: a customer-centric approach to sustainability. *Journal of the Academy of Marketing Science* 39 (1): 21–39.
110. Snoj, Boris in Vladimir Gabrijan. 2015. *Marketing: konceptualne in celostne razsežnosti*. Založba Pivec.
111. *Statistični urad Republike Slovenije*. Dostopno prek: <http://www.stat.si/> (10. marec 2016).
112. Stafford, James R.. 2009. RFM: a precursor to data mining. *Stafford SBSG*. Dostopno prek: <http://www.b-eye-network.com/view/10256>. (19. december 2015).

113. Steenkamp, Jan-Benedict EM, Harald J. Van Heerde in Inge Geyskens. 2010. What makes consumers willing to pay a price premium for national brands over private labels?. *Journal of Marketing Research* 47 (6): 1011–1024.
114. Steinhoff, Lena in Robert W. Palmatier. 2016. Understanding loyalty program effectiveness: managing target and bystander effects. *Journal of the Academy of Marketing Science* 44 (1): 88–107.
115. Stoeckl, Verena E. in Marius K. Luedicke. 2015. Doing well while doing good? An integrative review of marketing criticism and response. *Journal of Business Research* 68 (12): 2452–2463.
116. Šmid, Marko. 2004. Uporaba metod za odkrivanje znanj iz podatkov v trženju. *Marketing v poslovni strategiji – pot do uresničitve*, 9. Slovenska marketinška konferenca društva za marketing Slovenije in Časnika Finance, e-zbornik prispevkov, Časnik Finance d.o.o. in Društvo za marketing Slovenije, 50–56. Dostopno prek: <http://www.dmslo.si/media/smk.pdf>. (19. december 2015).
117. Tan, Pang-Ning, Vipin Kumar in Jaideep Srivastava. 2004. Selecting the right objective measure for association analysis. *Information Systems* 29 (4): 293–313.
118. Tan, Pang-Ning, Michael Steinbach in Vipin Kumar. 2006. *Introduction to data mining*. Boston: Pearson Addison Wesley.
119. *Tržni inšpektorat Republike Slovenije*. Dostopno prek: <http://www.ti.gov.si/> (25. januar 2016).
120. *Urad Republike Slovenije za varstvo potrošnikov*. Dostopno prek: <http://www.arhiv.uvp.gov.si/> (25. januar 2016).
121. do Vale, Rita Coelho, Pedro Verga Matos in Jorge Caiado. 2016. The impact of private labels on consumer store loyalty: An integrative perspective. *Journal of Retailing and Consumer Services* 28: 179–188.
122. Verma, Varsha, Dheeraj Sharma in Jagdish Sheth. 2016. Does relationship marketing matter in online retailing? A meta-analytic approach. *Journal of the Academy of Marketing Science* 44 (2): 206–217.
123. Vida, Irena, Janez Damjan in Ann Fairhurst. 2015. Ethnocentric tendencies and consumer purchase behavior in Central and Eastern Europe: the case of Slovenia. *Proceedings of the 1996 Multicultural Marketing conference* (49–54). Springer International Publishing.
124. Vukasović, Tina. 2013. *Vedenje porabnikov: celovit pristop k raziskovanju vedenja porabnikov*. Celje: Mednarodna fakulteta za družbene in poslovne študije.

125. Weinstein, Art. 1994. *Marketing segmentation: using demographics, psychographic and other niche marketing techniques to predict and model customer behaviour*. McGraw-Hill.
126. Weiss, Sholom M. in Nitin Indurkha. 1998. *Predictive data mining: a practical guide*. San Francisco: Morgan Kaufmann.
127. Witten, Ian H in Eibe Frank. 2005. *Data Mining: Practical Machine Learning Tools and Techniques*. Morgan Kaufmann.
128. Wulf, Kristof De, Gaby Odekerken-Schröder, Marie Hélène de Cannière in Claudia Van Oppen. 2003. What drives consumer participation to loyalty programs? A conjoint analytical approach. *Journal of Relationship Marketing* 2 (1–2): 69–83.
129. *Zakon o varstvu osebnih podatkov (ZVOP-1-UPB1)*. Ur. l. RS 94/2007 (16. oktober 2007).
130. *Zakon o varstvu potrošnikov (ZVPot-UPB2)*. Ur. l. RS 98/2004 (9. september 2004).
131. *Zakon o varstvu potrošnikov pred nepoštenimi poslovnimi praksami (ZVPNPP)*. Ur. l. RS 53/2007 (31. maj 2007).
132. *Zveza potrošnikov Slovenije*. Dostopno prek: <https://www.zps.si/> (25. januar 2016).
133. Žabkar, Vesna in Barbara Zbačnik. 2009. *Vloga trženja in trženjskega komuniciranja v podjetjih v Sloveniji*. Ljubljana: Ekonomska fakulteta, Enota za založništvo.

PRILOGE

PRILOGA A: Seznam uporabljenih kratic in simbolov

CRISP-DM = standardizirana metodologija za izvedbo procesa podatkovnega rudarjenja;

Engrotuš d.d. = Tuš;

ID = enoznačna identifikacijska številka;

ILP = induktivno logično programiranje;

IT = oddelek informacijskih tehnologij v podjetju;

Iz = izboljšava;

KARTICA = enoznačna identifikacijska številka kartice programa zvestobe Tuš kluba;

KDD = proces odkrivanja znanja v podatkih;

PD = podatkovno rudarjenje;

Po = podpora;

ReNPVP = Resolucija o nacionalnem programu varstva potrošnikov 2006–2010 (ReNPVP);

TK račun = Tuš klub račun oziroma enoznačna identifikacijska številka člana programa zvestobe Tuš kluba;

TOP_ZVESTI = segment najbolj zvestih kupcev trgovca Tuša;

TOP_LBZ = segment najbolj zvestih kupcev lastne blagovne znamke trgovca Tuša;

Za = zaupanje;

ZVOP-1 = Zakon o varstvu osebnih podatkov (ZVOP-1-UPB1);

ZVPot = Zakon o varstvu potrošnikov (ZVPot-UPB2);

ZVPNPP = Zakon o varstvu potrošnikov pred nepoštenimi poslovnimi praksami (ZVPNPP);

ZVPNPP = Zakon o varstvu potrošnikov pred nepoštenimi poslovnimi praksami (ZVPNPP).

PRILOGA B: Profil taktičnih segmentov kupcev

Tabela B.1: Lastnosti TOP_ZVESTI in TOP_LBZ kupcev po demografskih značilnostih.

SPOL	Celoten vzorec TK članov	TOP ZVESTI TUŠ	TOP ZVESTI LBZ
Moški	31 %	24 %	26 %
Ženske	69 %	76 %	74 %
STAROST	Celoten vzorec TK članov	TOP ZVESTI TUŠ	TOP ZVESTI LBZ
STAROST < 30	7 %	3 %	3 %
30 <= STAROST < 45	24 %	22 %	23 %
45 <= STAROST < 65	39 %	46 %	46 %
STAROST = > 65	17 %	17 %	17 %
ni podatka	12 %	12 %	11 %
REGIJA	Celoten vzorec TK članov	TOP ZVESTI TUŠ	TOP ZVESTI LBZ
Pomurska	7 %	6 %	6 %
Podravska	20 %	19 %	20 %
Koroška	7 %	7 %	11 %
Savinjska	18 %	19 %	18 %
Zasavska	3 %	2 %	2 %
Posavska	4 %	2 %	4 %
Jugovzhodna Slovenija	7 %	6 %	7 %
Osrednjeslovenska	20 %	21 %	18 %
Gorenjska	4 %	3 %	4 %
Primorsko-notranjska	2 %	2 %	2 %
Goriška	2 %	2 %	1 %
Obalno-kraška	6 %	10 %	7 %
TUJINA	1 %	0 %	1 %

Tabela B.2: Kontingenčna tabela segment TOP_ZVESTI glede na SPOL in izvorni izpis pripadajočega Hi-kvadrat testa iz programa za obdelavo podatkov.

			TOP_ZVESTI		SKUPAJ	
			NE	DA		
SPOL	ženski	% znotraj SPOL	88,6 %	11,4 %	100,0 %	
		% znotraj TOP_ZVESTI	68,5 %	76,4 %	69,3 %	
		% SKUPAJ	61,5 %	7,9 %	69,3 %	
	moški	% znotraj SPOL	92,1 %	7,9 %	100,0 %	
		% znotraj TOP_ZVESTI	31,5 %	23,6 %	30,7 %	
		% SKUPAJ	28,2 %	2,4 %	30,7 %	
SKUPAJ		% znotraj SPOL	89,7 %	10,3 %	100,0 %	
		% znotraj TOP_ZVESTI	100,0 %	100,0 %	100,0 %	
		% SKUPAJ	89,7 %	10,3 %	100,0 %	
Hi-kvadrat test		Value	Df	Asymp. Sig. (2-sided)	Exact Sig. (2-sided)	Exact Sig. (1-sided)
Pearson Chi-Square		18,942 ^a	1	,000		
Continuity Correction ^b		18,572	1	,000		
Likelihood Ratio		19,792	1	,000		
Fisher's Exact Test					,000	,000
Linear-by-Linear Association		18,939	1	,000		
N of Valid Cases		6997				

a. 0 cells (0,0 %) have expected count less than 5. The minimum expected count is 221,03.

b. Computed only for a 2x2 table

Tabela B.3: Kontingenčna tabela segment TOP_ZVESTI glede na STAROST in izvorni izpis pripadajočega Hi-kvadrat testa iz programa za obdelavo podatkov.

			TOP_ZVESTI		SKUPAJ
			NE	DA	
STAROST	STAROST < 30	% znotraj STAROST	96,0 %	4,0 %	100,0 %
		% znotraj TOP_ZVESTI	8,0 %	2,9 %	7,4 %
		% SKUPAJ	7,1 %	,3 %	7,4 %
	30 <= STAROST < 45	% znotraj STAROST	90,7 %	9,3 %	100,0 %
		% znotraj TOP_ZVESTI	24,5 %	21,8 %	24,2 %
		% SKUPAJ	21,9 %	2,2 %	24,2 %
	45 <= STAROST < 65	% znotraj STAROST	87,9 %	12,1 %	100,0 %
		% znotraj TOP_ZVESTI	38,7 %	46,5 %	39,5 %
		% SKUPAJ	34,7 %	4,8 %	39,5 %
	STAROST = > 65	% znotraj STAROST	89,7 %	10,3 %	100,0 %
		% znotraj TOP_ZVESTI	16,9 %	16,8 %	16,9 %
		% SKUPAJ	15,1 %	1,7 %	16,9 %
	ni podatka	% znotraj STAROST	89,7 %	10,3 %	100,0 %
		% znotraj TOP_ZVESTI	12,1 %	12,1 %	12,1 %
		% SKUPAJ	10,8 %	1,2 %	12,1 %
SKUPAJ	% znotraj STAROST	89,7 %	10,3 %	100,0 %	
	% znotraj TOP_ZVESTI	100,0 %	100,0 %	100,0 %	
	% SKUPAJ	89,7 %	10,3 %	100,0 %	

Hi-kvadrat test	Value	df	Asymp. Sig. (2-sided)
Pearson Chi-Square	33,964 ^a	4	,000
Likelihood Ratio	39,506	4	,000
Linear-by-Linear Association	8,757	1	,003
N of Valid Cases	6997		

a. 0 cells (0,0 %) have expected count less than 5. The minimum expected count is 53,58.

Tabela B.4: Kontingenčna tabela segment TOP_ZVESTI glede na REGIJO in izvorni izpis pripadajočega Hi-kvadrat testa iz programa za obdelavo podatkov.

			TOP_ZVESTI		SKUPAJ
			NE	DA	
REGIJA	Pomurska	% znotraj REGIJA	90,0 %	10,0 %	100,0 %
		% znotraj TOP_ZVESTI	6,6 %	6,4 %	6,6 %
		% SKUPAJ	5,9 %	,7 %	6,6 %
	Podravska	% znotraj REGIJA	90,1 %	9,9 %	100,0 %
		% znotraj TOP_ZVESTI	19,8 %	19,0 %	19,7 %
		% SKUPAJ	17,8 %	2,0 %	19,7 %
	Koroška	% znotraj REGIJA	88,4 %	11,6 %	100,0 %
		% znotraj TOP_ZVESTI	6,6 %	7,5 %	6,7 %
		% SKUPAJ	5,9 %	,8 %	6,7 %
	Savinjska	% znotraj REGIJA	89,3 %	10,7 %	100,0 %
		% znotraj TOP_ZVESTI	18,1 %	18,9 %	18,1 %
		% SKUPAJ	16,2 %	1,9 %	18,1 %
	Zasavska	% znotraj REGIJA	90,8 %	9,2 %	100,0 %
		% znotraj TOP_ZVESTI	2,8 %	2,5 %	2,8 %
		% SKUPAJ	2,5 %	,3 %	2,8 %
	Posavska	% znotraj REGIJA	93,5 %	6,5 %	100,0 %
		% znotraj TOP_ZVESTI	3,6 %	2,2 %	3,5 %
		% SKUPAJ	3,3 %	,2 %	3,5 %
	Jugovzhodna Slovenija	% znotraj REGIJA	91,5 %	8,5 %	100,0 %
		% znotraj TOP_ZVESTI	7,2 %	5,8 %	7,1 %
		% SKUPAJ	6,5 %	,6 %	7,1 %
	Osrednjeslovenska	% znotraj REGIJA	89,3 %	10,7 %	100,0 %
		% znotraj TOP_ZVESTI	19,6 %	20,5 %	19,7 %
		% SKUPAJ	17,6 %	2,1 %	19,7 %
	Gorenjska	% znotraj REGIJA	93,0%	7,0 %	100,0 %
		% znotraj TOP_ZVESTI	4,6 %	3,1 %	4,5 %
		% SKUPAJ	4,2 %	,3 %	4,5 %
	Notranjsko-kraška	% znotraj REGIJA	90,2 %	9,8 %	100,0 %
		% znotraj TOP_ZVESTI	2,2 %	2,1 %	2,2 %
		% SKUPAJ	2,0 %	,2 %	2,2 %
	Goriška	% znotraj REGIJA	91,0 %	9,0 %	100,0 %
		% znotraj TOP_ZVESTI	1,8 %	1,5 %	1,7 %
		% SKUPAJ	1,6 %	,2 %	1,7 %
	Obalno-kraška	% znotraj REGIJA	83,4 %	16,6 %	100,0 %
		% znotraj TOP_ZVESTI	5,8 %	10,1 %	6,3 %
		% SKUPAJ	5,2 %	1,0 %	6,3 %
	TUJINA	% znotraj REGIJA	96,3 %	3,8 %	100,0 %
		% znotraj TOP_ZVESTI	1,2 %	,4 %	1,1 %
		% SKUPAJ	1,1 %	,0 %	1,1 %
SKUPAJ		% znotraj REGIJA	89,7 %	10,3 %	100,0 %
		% znotraj TOP_ZVESTI	100,0 %	100,0 %	100,0 %
		% SKUPAJ	89,7 %	10,3 %	100,0 %
Hi-kvadrat test		Value	df	Asymp. Sig. (2-sided)	
Pearson Chi-Square		33,984 ^a	12	,001	
Likelihood Ratio		33,416	12	,001	
Linear-by-Linear Association		1,223	1	,269	
N of Valid Cases		6997			

a. 0 cells (0,0 %) have expected count less than 5. The minimum expected count is 8,24.

Tabela B.5: Kontingenčna tabela segment TOP_LBZ glede na SPOL in izvorni izpis pripadajočega Hi-kvadrat testa iz programa za obdelavo podatkov.

			TOP_LBZ		SKUPAJ	
			NE	DA		
SPOL	ženski	% znotraj SPOL	91,3 %	8,7 %	100,0 %	
		% znotraj TOP_LBZ	68,9 %	74,3 %	69,3 %	
		% SKUPAJ	63,3 %	6,0 %	69,3 %	
	Moški	% znotraj SPOL	93,2 %	6,8 %	100,0 %	
		% znotraj TOP_LBZ	31,1 %	25,7 %	30,7 %	
		% SKUPAJ	28,6 %	2,1 %	30,7 %	
SKUPAJ	% znotraj SPOL	91,9 %	8,1 %	100,0 %		
	% znotraj TOP_LBZ	100,0 %	100,0 %	100,0 %		
	% SKUPAJ	91,9 %	8,1 %	100,0 %		
Hi-kvadrat test		Value	df	Asymp. Sig. (2-sided)	Exact Sig. (2-sided)	Exact Sig. (1-sided)
Pearson Chi-Square		7,275 ^a	1	,007		
Continuity Correction ^b		7,021	1	,008		
Likelihood Ratio		7,501	1	,006		
Fisher's Exact Test					,007	,004
Linear-by-Linear Association		7,274	1	,007		
N of Valid Cases		6997				

a. 0 cells (0,0 %) have expected count less than 5. The minimum expected count is 174,43.

b. Computed only for a 2x2 table.

Tabela B.6: Kontingenčna tabela segment TOP_LBZ glede na STAROST in izvorni izpis pripadajočega Hi-kvadrat testa iz programa za obdelavo podatkov.

Hi-kvadrat test			TOP_LBZ		SKUPAJ
			NE	DA	
STAROST	STAROST < 30	% znotraj STAROST	96,3 %	3,7 %	100,0 %
		% znotraj TOP_LBZ	7,8 %	3,3 %	7,4 %
		% SKUPAJ	7,2 %	,3 %	7,4 %
	30 <= STAROST < 45	% znotraj STAROST	92,4 %	7,6 %	100,0 %
		% znotraj TOP_LBZ	24,3 %	22,7 %	24,2 %
		% SKUPAJ	22,3 %	1,8 %	24,2 %
	45 <= STAROST < 65	% znotraj STAROST	90,6 %	9,4 %	100,0 %
		% znotraj TOP_LBZ	38,9 %	45,5 %	39,5 %
		% SKUPAJ	35,8 %	3,7 %	39,5 %
	STAROST => 65	% znotraj STAROST	91,7 %	8,3 %	100,0 %
		% znotraj TOP_LBZ	16,8 %	17,2 %	16,9 %
		% SKUPAJ	15,4 %	1,4 %	16,9 %
ni podatka	% znotraj STAROST	92,4 %	7,6 %	100,0 %	
	% znotraj TOP_LBZ	12,1 %	11,2 %	12,1 %	
	% SKUPAJ	11,1 %	,9 %	12,1 %	
SKUPAJ	% znotraj STAROST	91,9 %	8,1 %	100,0 %	
	% znotraj TOP_LBZ	100,0 %	100,0 %	100,0 %	
	% SKUPAJ	91,9 %	8,1 %	100,0 %	

Hi-kvadrat test	Value	df	Asymp. Sig. (2-sided)
Pearson Chi-Square	20,667 ^a	4	,000
Likelihood Ratio	23,768	4	,000
Linear-by-Linear Association	3,708	1	,054
N of Valid Cases	6997		

a. 0 cells (0,0 %) have expected count less than 5. The minimum expected count is 42,29.

Tabela B.7: Kontingenčna tabela segment TOP_LBZ glede na REGIJO in izvorni izpis pripadajočega Hi-kvadrat testa iz programa za obdelavo podatkov.

Hi-kvadrat test			TOP_LBZ		SKUPAJ
			NE	DA	
REGIJA	Pomurska	% znotraj REGIJA	92,8 %	7,2 %	100,0 %
		% znotraj TOP_LBZ	6,6 %	5,8 %	6,6 %
		% SKUPAJ	6,1 %	,5 %	6,6 %
	Podravska	% znotraj REGIJA	91,8 %	8,2 %	100,0 %
		% znotraj TOP_LBZ	19,7 %	19,9 %	19,7 %
		% SKUPAJ	18,1 %	1,6 %	19,7 %
	Koroška	% znotraj REGIJA	86,3 %	13,7 %	100,0 %
		% znotraj TOP_LBZ	6,3 %	11,2 %	6,7 %
		% SKUPAJ	5,8 %	,9 %	6,7 %
	Savinjska	% znotraj REGIJA	92,0 %	8,0 %	100,0 %
		% znotraj TOP_LBZ	18,2 %	17,8 %	18,1 %
		% SKUPAJ	16,7 %	1,4 %	18,1 %
	Zasavska	% znotraj REGIJA	93,4 %	6,6 %	100,0 %
		% znotraj TOP_LBZ	2,8 %	2,3 %	2,8 %
		% SKUPAJ	2,6 %	,2 %	2,8 %
	Posavska	% znotraj REGIJA	91,8 %	8,2 %	100,0 %
		% znotraj TOP_LBZ	3,5 %	3,5 %	3,5 %
		% SKUPAJ	3,2 %	,3 %	3,5 %
	Jugovzhodna Slovenija	% znotraj REGIJA	92,3 %	7,7 %	100,0 %
		% znotraj TOP_LBZ	7,1 %	6,7 %	7,1 %
		% SKUPAJ	6,5 %	,5 %	7,1 %
	Osrednjeslovenska	% znotraj REGIJA	92,4 %	7,6 %	100,0 %
		% znotraj TOP_LBZ	19,8 %	18,5 %	19,7 %
		% SKUPAJ	18,2 %	1,5 %	19,7 %
	Gorenjska	% znotraj REGIJA	93,3 %	6,7 %	100,0 %
		% znotraj TOP_LBZ	4,5 %	3,7 %	4,5 %
		% SKUPAJ	4,2 %	,3 %	4,5 %
	Notranjsko-kraška	% znotraj REGIJA	94,1 %	5,9 %	100,0 %
		% znotraj TOP_LBZ	2,2 %	1,6 %	2,2 %
		% SKUPAJ	2,1 %	,1 %	2,2 %
	Goriška	% znotraj REGIJA	93,4 %	6,6 %	100,0 %
		% znotraj TOP_LBZ	1,8 %	1,4 %	1,7 %
		% SKUPAJ	1,6 %	,1 %	1,7 %
	Obalno-kraška	% znotraj REGIJA	90,7 %	9,3 %	100,0 %
		% znotraj TOP_LBZ	6,2 %	7,2 %	6,3 %
		% SKUPAJ	5,7 %	,6 %	6,3 %
TUJINA		% znotraj REGIJA	96,3 %	3,8 %	100,0 %
		% znotraj TOP_LBZ	1,2 %	,5 %	1,1 %
		% SKUPAJ	1,1 %	,0 %	1,1 %
SKUPAJ		% znotraj REGIJA	91,9 %	8,1 %	100,0 %
		% znotraj TOP_LBZ	100,0 %	100,0 %	100,0 %
		% SKUPAJ	91,9 %	8,1 %	100,0 %

Hi-kvadrat test	Value	df	Asymp. Sig. (2-sided)
Pearson Chi-Square	26,438 ^a	12	,009
Likelihood Ratio	24,083	12	,020
Linear-by-Linear Association	1,711	1	,191
N of Valid Cases	6997		

a. 0 cells (0,0 %) have expected count less than 5. The minimum expected count is 6,51.

Tabela B.8: Statistični kazalniki po statističnih regijah za leto 2013.

Statistični kazalniki	Povprečna starost (leta)	Delež prebivalcev, starih 65 let ali več (%)	Koeficient starostne odvisnosti	Koeficient starostne odvisnosti mladih	Koeficient starostne odvisnosti starih	Indeks feminitet	Gostota naseljenosti	Stopnja delovne aktivnosti	Stopnja brezposelnosti	Naravni prirast prebivalstva	Skupni prirast na 1000 prebivalcev	Prezgodnja umrljivost (%)	Ekonomski rast	Površina km ²
REGIJA	2013H1	2013H1	2013H1	2013H1	2013H1	2013H1	2013H1	2013	2013	2013	2013	2013	2013	2013H1
Pomurska	43,5	18,2	45,5	19	26,5	104,2	88,3	42,9	17,2	-340	-7,6	21,4	69,5	1337
Podravska	42,9	17,9	45	19,1	25,9	102,2	149	43,6	14,6	-434	0,3	20,8	82,4	2170
Koroška	42,4	16,9	45,3	20,8	24,6	99,1	69,3	45,8	13	-15	-7,7	23,7	79,1	1041
Savinjska	41,9	16,5	45,6	21,5	24,1	100,3	109,2	45,7	14	203	-1,4	20,1	90,2	2384
Zasavska	43,6	18,6	46,3	19,1	27,2	103,9	164,8	42,5	15,9	-106	-11,9	19,8	62,5	264
Posavska	42,7	17,6	46,4	20,7	25,8	98,8	79,3	44,1	15,7	-70	-3,6	21,6	86,3	885
Jugovzhodna Slovenija	41,3	16,1	45,9	22,4	23,5	98,9	53,3	46,1	14,3	214	-0,7	20,1	95	2675
Ostrednjeslovenska	41	16,2	46,1	22,4	23,7	104,8	212	47	11,4	1757	8,5	19,9	141,6	2555
Gorenjska	41,6	17,3	48,9	23,1	25,8	102,3	95,5	47,1	9,8	502	-0,4	18,8	85,2	2137
Primorsko-notranjska	42,6	17,6	47,4	21,4	26	98,4	36	46,9	12,2	64	1,4	17,5	69,7	1456
Goriška	43,3	18,6	48,9	21,2	27,7	100,5	51,2	45,2	11,4	-14	-5,3	17,7	90,4	2325
Obalno-kraška	43,3	17,6	44,3	19	25,3	100,7	107,2	45,9	11,7	16	8,1	21,3	98,2	1044

Statistični kazalniki	Mio EUR (fiksni tečaj 2007)	Struktura (Slovenija = 100%)	Na prebivalca, EUR (tekoči tečaj)	Na prebivalca, indeks ravnosti (Slovenija vsa leta = 100)	Indeks delovne migracije	Povprečna mesečna bruto plača	Povprečna mesečna neto plača	Indeks povprečne mesečne bruto plače	Indeks povprečne mesečne neto plače	Delež otrok vključenih v vrtec - SKUPAJ (%)	Delež otrok vključenih v vrtec - prvo starostno obdobje %	Delež otrok vključenih v vrtec - drugo starostno obdobje %	Obsojeni polnoletni in mladoletni na 1000 prebivalcev	Število obsojenih in mladoletnih oseb
REGIJA	2013	2013	2013	2013	2013	2013	2013	2013	2013	2013	2013	2013	2013	2013
Pomurska	1396	3,9	11858	68	90,2	1336,85	897,19	87,8	90	75,4	54,1	88,9	5,9	695
Podravska	4645	12,9	14390	82,5	96,1	1394,51	924,01	91,6	92,7	75	54,2	88,4	6,2	1998
Koroška	997	2,8	13850	79,4	87	1406,19	931,96	92,3	93,5	68,8	41,2	86	5,5	396
Savinjska	4108	11,4	15769	90,4	96,5	1396,9	927,71	91,7	93	75,9	56,3	88,7	4,9	1280
Zasavska	474	1,3	10941	62,8	69,4	1414,36	934,58	92,9	93,7	66,9	41,6	83,1	6,6	286
Posavska	1067	3	15181	87,1	79,6	1415,44	938,05	92,9	94,1	68,2	51,9	79,4	4,2	296
Jugovzhodna Slovenija	2361	6,6	16552	94,9	88,7	1516,62	999,64	99,6	100,3	72,6	53,7	85,5	8,3	1184
Ostrednjeslovenska	13373	37,2	24647	141,4	126	1685	1083,75	110,6	108,7	79,1	59,7	91,9	5,1	2746
Gorenjska	3044	8,5	14923	85,6	83,9	1508,29	992,31	99	99,5	70,9	44,9	87,7	3,1	622
Primorsko-notranjska	643	1,8	12232	70,2	74,9	1336,21	895,73	87,7	89,9	67,8	49,4	80,8	3,7	192
Goriška	1879	5,2	15782	90,5	96,3	1458,25	969,71	95,7	97,3	71,3	45,4	89	2,5	295
Obalno-kraška	1922	5,4	17133	98,3	97,4	1494,41	979,33	98,1	98,2	77,1	59,2	88,6	5,6	623

Statistični kazalniki	Število stanovanj	Število stanovanj na 1.000 prebivalcev	Število naseljenih stanovanj	Število počitniških stanovanj	Povprečna uporabna površina stanovanja (m ²)	Povprečna uporabna površina (m ²) naseljenega stanovanja	Povprečna uporabna površina (m ²) na stanovalca	Povprečno število oseb v stanovanju	Delež tri ali več sobnih stanovanj (%)	Delež novih stanovanj, grajenih po letu 2005 (%)	Delež naseljenih stanovanj, ki nimajo vseh elementov osnovne infrastrukture (%)	Delež naseljenih stanovanj z manj kot 10 m ² uporabne površine na osebo (%)	Število osebnih avtomobilov na 1.000 prebivalcev	Povprečna starost osebnih avtomobilov
REGIJA	2011	2011	2011	2011	2011	2011	2011	2011	2011	2011	2011	2011	2013	2013
Pomurska	48268	405,1	37365	1062	85,7	89	28,2	3,1	65,1	2,4	8,5	2,9	504	9,2
Podravska	135995	420,9	108839	2277	77,1	79,6	27,5	2,9	56,8	5,3	5,8	3,2	496	9,2
Koroška	26682	368,1	22585	634	85,1	86,4	27,2	3,2	60,1	3,1	3,9	2,9	507	8,9
Savinjska	103340	397,9	82981	2161	78,9	80,3	26,1	3,1	60,4	4	5,3	4	512	9,4
Zasavska	17974	406,4	15822	291	69,9	70,5	25,5	2,7	46,8	1,7	4,3	3,7	469	9
Posavska	29850	425,4	21863	1243	80,3	84,5	27	3,1	59,6	3	7,2	3,5	529	9,9
Jugovzhodna Slovenija	56995	400	42374	2415	82,5	87	26,6	3,2	59,9	4,2	7,8	3,8	517	9,2
Ostrednjeslovenska	217885	408,6	177130	2884	77,3	79,3	27,2	2,9	58,2	6,8	3,6	4	510	8,5
Gorenjska	78814	387,4	64702	3415	84,8	87,2	27,9	3,1	64,1	4,9	2,7	3,3	516	8,9
Primorsko-notranjska	22621	432,6	17537	484	83,7	85	28,9	2,9	65,2	4,4	5,6	2,5	553	9,6
Goriška	51215	429,9	39371	1596	84,8	87,5	29,4	3	72,7	3,5	4,6	2,2	577	10
Obalno-kraška	55017	496,7	39558	2278	74,2	77,5	28,2	2,7	59,9	6,3	4,9	4,3	558	9,1

Statistični kazalniki	Investicije na prebivalca (EUR)	Regionalni bruto domači proizvod na prebivalca, indeks ravnosti (Slovenija vsa leta = 100)	Število študentov v terciarnem izobraževanju na 1.000 prebivalcev po regijah stalnega prebivališča (število/1.000 prebivalcev)	Poraba vode, dobavljene iz javnega vodovoda, v gospodinjstvih na prebivalca (m ³ /prebivalca)	Komunalni odpadki, zbrani z javnim odvozom odpadkov na prebivalca (kilogram/prebivalca)
REGIJA	2013	2013	2013	2013	2013
Pomurska	1218	69,5	38,7	28,8	278
Podravska	1299	82,4	40	39,4	312
Koroška	1555	79,1	46,1	29,1	233
Savinjska	3653	90,2	44,9	42,8	288
Zasavska	969	62,5	38,9	35	312
Posavska	2069	86,3	42,8	31,7	322
Jugovzhodna Slovenija	2956	95	47	29,5	266
Ostrednjeslovenska	3004	141,6	43,4	36,8	366
Gorenjska	1623	85,2	43,7	48,4	299
Primorsko-notranjska	1447	69,7	41,5	39,3	297
Goriška	1231	90,4	47,5	52,1	355
Obalno-kraška	1697	98,2	35,1	28,8	384

Vir: Statistični Urad Republike Slovenije.

PRILOGA C: Primeri povezovalnih pravil

Tabela C.1: Izbor primerov povezovalnih pravil na nivoju blagovnih skupin NAZIV_BS.

POPOGOJ	PREDPOGOJ	Podpora	Zaupanje	Izboljšava
NAZIV_BS_MESO SVINJSKO – SVEŽE ODPRT	NAZIV_BS_PIVO DOMAČE – PLOČEVINKE and NAZIV_BS_ZELENJAVA SVEŽA OBSTOJNA	1,9 %	16,3 %	2,4
NAZIV_BS_MESO PIŠČANČJE – SVEŽE ODP.	NAZIV_BS_SADJE SVEŽE OBSTOJNO and NAZIV_BS_ZELENJAVA SVEŽA OBSTOJNA and NAZIV_BS_ZELENJAVA SVEŽA OBČUTLJ.	1,7 %	16,0 %	2,6
NAZIV_BS_MESO SVINJSKO – SVEŽE ODPRT	NAZIV_BS_PIVO DOMAČE – PLOČEVINKE and NAZIV_BS_ZELENJAVA SVEŽA OBČUTLJ.	2,4 %	15,0 %	2,2
NAZIV_BS_MESO SVINJSKO – SVEŽE ODPRT	NAZIV_BS_SADJE SVEŽE OBSTOJNO and NAZIV_BS_ZELENJAVA SVEŽA OBSTOJNA and NAZIV_BS_ZELENJAVA SVEŽA OBČUTLJ.	1,7 %	14,5 %	2,1
NAZIV_BS_MESO SVINJSKO – SVEŽE ODPRT	NAZIV_BS_ZELENJAVA SVEŽA OBSTOJNA and NAZIV_BS_ZELENJAVA SVEŽA OBČUTLJ. and NAZIV_BS_SADJE SVEŽE OBČUTLJIVO	3,4 %	14,2 %	2,1
NAZIV_BS_MESO PIŠČANČJE – SVEŽE ODP.	NAZIV_BS_PIVO DOMAČE – PLOČEVINKE and NAZIV_BS_ZELENJAVA SVEŽA OBSTOJNA	1,9 %	14,1 %	2,3
NAZIV_BS_MESO PIŠČANČJE – SVEŽE ODP.	NAZIV_BS_PIVO DOMAČE – PLOČEVINKE and NAZIV_BS_ZELENJAVA SVEŽA OBČUTLJ.	2,4 %	13,5 %	2,2
NAZIV_BS_MESO SVINJSKO – SVEŽE ODPRT	NAZIV_BS_PIVO DOMAČE – PLOČEVINKE and NAZIV_BS_SADJE SVEŽE OBSTOJNO	1,3 %	12,9 %	1,9
NAZIV_BS_MESO SVINJSKO – SVEŽE ODPRT	NAZIV_BS_SADJE SVEŽE OBSTOJNO and NAZIV_BS_ZELENJAVA SVEŽA OBSTOJNA	3,3 %	12,6 %	1,8
NAZIV_BS_MESO SVINJSKO – SVEŽE ODPRT	NAZIV_BS_PIVO DOMAČE – PLOČEVINKE and NAZIV_BS_SADJE SVEŽE OBČUTLJIVO	2,6 %	12,4 %	1,8
NAZIV_BS_MESO PIŠČANČJE – SVEŽE ODP.	NAZIV_BS_PIVO DOMAČE – PLOČEVINKE and NAZIV_BS_SADJE SVEŽE OBSTOJNO	1,3 %	11,6 %	2,2
NAZIV_BS_IZDELKI MESNICA LASTNA P.	NAZIV_BS_PIVO DOMAČE – PLOČEVINKE and NAZIV_BS_ZELENJAVA SVEŽA OBČUTLJ.	2,4 %	11,2 %	2,3
NAZIV_BS_MESO PIŠČANČJE – SVEŽE ODP.	NAZIV_BS_PIVO DOMAČE – PLOČEVINKE and NAZIV_BS_SADJE SVEŽE OBČUTLJIVO	2,6 %	11,2 %	1,8
NAZIV_BS_IZDELKI MESNICA LASTNA P.	NAZIV_BS_PIVO DOMAČE – PLOČEVINKE and NAZIV_BS_ZELENJAVA SVEŽA OBSTOJNA	1,9 %	11,1 %	2,3
NAZIV_BS_MESO GOVEJE – MLADO SV.ODP.	NAZIV_BS_PIVO DOMAČE – PLOČEVINKE and NAZIV_BS_ZELENJAVA SVEŽA OBSTOJNA	1,9 %	8,8 %	2,2
NAZIV_BS_IZDELKI MESNICA LASTNA P.	NAZIV_BS_PIVO DOMAČE – PLOČEVINKE and NAZIV_BS_SADJE SVEŽE OBSTOJNO	1,3 %	8,6 %	1,8
NAZIV_BS_IZDELKI MESNICA LASTNA P.	NAZIV_BS_PIVO DOMAČE – PLOČEVINKE and NAZIV_BS_SADJE SVEŽE OBČUTLJIVO	2,6 %	8,1 %	1,7
NAZIV_BS_MESO GOVEJE – MLADO SV.ODP.	NAZIV_BS_PIVO DOMAČE – PLOČEVINKE and NAZIV_BS_ZELENJAVA SVEŽA OBČUTLJ.	2,4 %	7,6 %	1,5
NAZIV_BS_MESO GOVEJE – MLADO SV.ODP.	NAZIV_BS_PIVO DOMAČE – PLOČEVINKE and NAZIV_BS_SADJE SVEŽE OBSTOJNO	1,3 %	7,5 %	1,9
NAZIV_BS_MESO GOVEJE – MLADO SV.ODP.	NAZIV_BS_PIVO DOMAČE – PLOČEVINKE and NAZIV_BS_SADJE SVEŽE OBČUTLJIVO	2,6 %	6,1 %	1,5
NAZIV_BS_MESO PIŠČANČJE – SVEŽE PAK.	NAZIV_BS_PIVO DOMAČE – PLOČEVINKE and NAZIV_BS_ZELENJAVA SVEŽA OBČUTLJ.	2,4 %	5,6 %	2,0
NAZIV_BS_MESO PIŠČANČJE – SVEŽE PAK.	NAZIV_BS_PIVO DOMAČE – PLOČEVINKE and NAZIV_BS_ZELENJAVA SVEŽA OBSTOJNA	1,9 %	5,3 %	1,9
NAZIV_BS_MESO SVINJSKO – SVEŽE PAKIR	NAZIV_BS_PIVO DOMAČE – PLOČEVINKE and NAZIV_BS_ZELENJAVA SVEŽA OBČUTLJ.	2,4 %	5,2 %	2,2

PRILOGA Č: Artikli, ki se pogosto pojavljajo skupaj v nakupni košarici

Tabela Č.1: Primeri povezovalnih pravil na najnižjem nivoju blagovne skupine (NAZIV_BS) z največjo stopnjo podpore, na vzorcu 441415 nakupnih košaric.

POPOGOJ	PREPOGOJ	Podpora	Zaupanje	Izboljšava
NAZIV_BS_SUHO SADJE – PAKIRANO	SADJE SVEŽE OBČUTLJIVO ⁹¹	29,2 % ⁹²	5,4 %	1,7
NAZIV_BS_KRUH DOPEKA	SADJE SVEŽE OBČUTLJIVO	29,2 %	5,4 %	1,2
NAZIV_BS_MESO GOVEJE-MLADO SV.ODP.	SADJE SVEŽE OBČUTLJIVO	29,2 %	5,3 %	1,3
NAZIV_BS_SKUTA NAVADNA	SADJE SVEŽE OBČUTLJIVO	29,2 %	5,5 %	1,4
NAZIV_BS_SMETANA SLADKA	SADJE SVEŽE OBČUTLJIVO	29,2 %	5,7 %	1,5
NAZIV_BS_BRISAČE PAPIRNATE	SADJE SVEŽE OBČUTLJIVO	29,2 %	5,3 %	1,3
NAZIV_BS_ŽVEČILNI GUMI	SADJE SVEŽE OBČUTLJIVO	29,2 %	6,2 %	1,1
NAZIV_BS_IZDELKI MESNICA LASTNA P.	SADJE SVEŽE OBČUTLJIVO	29,2 %	5,8 %	1,2
NAZIV_BS_HRENOVKE VP	SADJE SVEŽE OBČUTLJIVO	29,2 %	6,0 %	1,2
NAZIV_BS_ČOKOLADA 100G	SADJE SVEŽE OBČUTLJIVO	29,2 %	7,0 %	1,3
NAZIV_BS_MASLO	SADJE SVEŽE OBČUTLJIVO	29,2 %	6,8 %	1,5
NAZIV_BS_SVEŽE TESTO IN IZD.OSTALO	SADJE SVEŽE OBČUTLJIVO	29,2 %	6,7 %	1,4
NAZIV_BS_JOGURTI PROBIO SADNI	SADJE SVEŽE OBČUTLJIVO	29,2 %	8,4 %	1,5
NAZIV_BS_ŠUNKA	SADJE SVEŽE OBČUTLJIVO	29,2 %	7,1 %	1,2
NAZIV_BS_DESERTI – DROBNI SLADEK P	SADJE SVEŽE OBČUTLJIVO	29,2 %	7,8 %	1,3
NAZIV_BS_MOKA PŠENIČNA	SADJE SVEŽE OBČUTLJIVO	29,2 %	7,1 %	1,4
NAZIV_BS_SLADKOR NAVADEN	SADJE SVEŽE OBČUTLJIVO	29,2 %	6,9 %	1,3
NAZIV_BS_MESO PIŠČANČJE – SVEŽE ODP.	SADJE SVEŽE OBČUTLJIVO	29,2 %	8,0 %	1,3
NAZIV_BS_KLOBASE POLTRAJNE	SADJE SVEŽE OBČUTLJIVO	29,2 %	8,0 %	1,1
NAZIV_BS_MESO SVINJSKO-SVEŽE ODPRT	SADJE SVEŽE OBČUTLJIVO	29,2 %	8,1 %	1,2
NAZIV_BS_TOALETNI PAPIR ROLICE	SADJE SVEŽE OBČUTLJIVO	29,2 %	8,2 %	1,3
NAZIV_BS_PEKOVSKO PECIVO LAST.PEKA	SADJE SVEŽE OBČUTLJIVO	29,2 %	9,7 %	1,1
NAZIV_BS_JOGURTI NAVADNI	SADJE SVEŽE OBČUTLJIVO	29,2 %	11,3 %	1,4
NAZIV_BS_VODA GAZIRANA	SADJE SVEŽE OBČUTLJIVO	29,2 %	9,9 %	1,2
NAZIV_BS_PIVO DOMAČE – PLOČEVINKE	SADJE SVEŽE OBČUTLJIVO	29,2 %	9,0 %	1,4
NAZIV_BS_JAJCA	SADJE SVEŽE OBČUTLJIVO	29,2 %	10,8 %	1,3
NAZIV_BS_JOGURTI SADNI	SADJE SVEŽE OBČUTLJIVO	29,2 %	12,4 %	1,4
NAZIV_BS_PAŠTETA – MESNA KONZERVA	SADJE SVEŽE OBČUTLJIVO	29,2 %	9,9 %	1,2
NAZIV_BS_POSEBNA KLOBASA	SADJE SVEŽE OBČUTLJIVO	29,2 %	11,4 %	1,1
NAZIV_BS_PEKOVSKO PECIVO DOPEKA	SADJE SVEŽE OBČUTLJIVO	29,2 %	14,8 %	1,1
NAZIV_BS_SMETANA KISLA	SADJE SVEŽE OBČUTLJIVO	29,2 %	13,2 %	1,3
NAZIV_BS_SIR DELIKATESNI – ODPRTI	SADJE SVEŽE OBČUTLJIVO	29,2 %	14,5 %	1,2
NAZIV_BS_SADJE SVEŽE OBSTOJNO	SADJE SVEŽE OBČUTLJIVO	29,2 %	22,5 %	1,7
NAZIV_BS_KRUH SVEŽI OSNOVNI	SADJE SVEŽE OBČUTLJIVO	29,2 %	19,2 %	1,1
NAZIV_BS_KAVA	SADJE SVEŽE OBČUTLJIVO	29,2 %	16,7 %	1,2
NAZIV_BS_ZELENJAVA SVEŽA OBSTOJNA	SADJE SVEŽE OBČUTLJIVO	29,2 %	23,7 %	1,4
NAZIV_BS_MLEKO TRAJNO	SADJE SVEŽE OBČUTLJIVO	29,2 %	22,6 %	1,3
NAZIV_BS_ZELENJAVA SVEŽA OBČUTLJ.	SADJE SVEŽE OBČUTLJIVO	29,2 %	30,9 %	1,4

⁹¹ Krajšano od »NAZIV_BS_SADJE_SVEŽE_OBČUTLJIVO«.

⁹² Število transakcij pri podpori 29,2 % je 128962.

PRILOGA D: Primer personalizirane direktne pošte trgovca Tuš v letu 2016

Slika D.1: Sprednja stran personalizirane direktne pošte trgovca Tuš z veljavnostjo od 3. 2. 2016 do 16. 2. 2016.

SUPER KUPONI ZA SUPER POPUSTE ZA ČLANE TUŠ KLUBA!

Kupone unovčite v trgovinah in franšizah Tuš od 3. 2. 2016 do 16. 2. 2016 oz. do odprodaje zalog v tem obdobju.



NAJBOLJŠI tekoči detergent!*

Persil Universal Gel v primerjavi z drugimi premium izdelki – rezultat internega testa, 20 °C

Spremljajte ugodnosti Tuš kluba na www.tus.si in ne spreglejte super ugodnosti tudi pri Tuš klub partnerjih. Skladno z ZVOP-1 lahko kadarkoli zahtevate preključitev uporabe vaših osebnih podatkov za obveščanje o ugodnostih Tuš kluba s klicem na brezplačno tel. številko 080 13 10. O odjavi boste s strani Centra za pomoč strankam obveščeni takoj, med telefonskim pogovorom.

Kupon velja od 3. 2. do 16. 2. 2016, za nakup največ 6 izdelkov.

S KUPONOM

-40 %



PERSIL
• detergent za pranje perila
• gel, več vrst, 60 pranj
• pranje, več vrst, 60 pranj
• kapsule SmartCare, Regular, Lavanda in Color, 30 pranj
• kapsule, 60 pranj, Regular in Color, 30 pranj

7,99 €

Redna cena 13,99 €

Kupon velja od 3. 2. do 16. 2. 2016, za nakup največ 6 izdelkov.

S KUPONOM

-50 %



REX
• detergent za pranje perila
• gel, več vrst, 60 pranj
• pranje, več vrst, 60 pranj

6,99 €

Redna cena 13,98 €

Kupon velja od 3. 2. do 16. 2. 2016, za nakup največ 6 izdelkov.

S KUPONOM

-30 %



PERWOLL
• specialni detergent za pranje perila
• več vrst, 18, 60, 90

Kupon velja od 3. 2. do 16. 2. 2016, za nakup največ 6 izdelkov.

S KUPONOM

-50 %



SILAN
• mešanica za pranje
• več vrst, 13L, 60 pranj, 60 pranj

2,49 €

Redna cena 4,98 €

Kupon velja od 3. 2. do 16. 2. 2016, za nakup največ 6 izdelkov.

S KUPONOM

-30 %



PRIL
• detergent za nujno pomivanje posode
• več vrst, 900 ml

1,74 €

Redna cena 2,49 €

Kupon velja od 3. 2. do 16. 2. 2016, za nakup največ 6 izdelkov.

S KUPONOM

-50 %



SOMAT
• detergent za strojno pomivanje posode
• Gold, 44 tablet
• All in 1, 56 tablet
• Classic, 72 tablet
• kapsule, 36 kos
• gel, 3L, 60 pranj

6,99 €

Redna cena 13,99 €

Kupon velja od 3. 2. do 16. 2. 2016, za nakup največ 6 izdelkov.

S KUPONOM

-50 %



SOMAT
• dodatki za strojno pomivanje posode
• sumpolir, dodatki za stropi
• 750 ml, 1000 ml, 1500 ml

Kupon velja od 3. 2. do 16. 2. 2016, za nakup največ 6 izdelkov.

S KUPONOM

-45 %



BREF
• WC čistilka ali WC čistilo
• Power Aktiv 100 g, Blue Aktiv 10 g, Duo Aktiv 50 ml, Power Aktiv 2000 g, Blue Aktiv 200 g, Duo Aktiv 1000 ml ali 3000 ml, WC, gel 360 ml
• čistilca 750 ml, WC, Bref Leston 750 ml

Kupon velja od 3. 2. do 16. 2. 2016, za nakup največ 6 izdelkov.

S KUPONOM

-50 %



CLIN
• čistilo za okna
• Leston ali Apple

0,99 €

Redna cena 1,99 €

Slika D2: Zadnja stran personalizirane direktne pošte trgovca Tuš z veljavnostjo od 3. 2. 2016 do 16. 2. 2016.



NDP

Engrotuš d.o.o.
Cesta v Trnovlje 10A · 3000 Celje · Slovenija

Poštnina plačana
pri pošti 1102 Ljubljana



Izkoristite kupone za atraktivne popuste!

Gospa
Anja Šostar
Zadobrova 98
3211 Škofja vas



<p>Kupon velja v trgovinah in franšizah Tuš od 3. 2. do 16. 2. 2016 oz. do odprodaje zalog v tem obdobju. Unovčljiv je ob predložitvi Tuš klub kartice ob enkratnem nakupu enega ali do največ 6, enakih ali različnih, na kuponu navedenih izdelkov. Velja za količine, običajne za gospodinjске nakupe. Ne velja v Tuš drogerijah, Tuš Cash&Carry, za akcijske izdelke, na odložena plačila in za pravne osebe. Popusti se ne seštevajo.</p> <div style="display: flex; align-items: center;"> <p style="font-size: 8px;">Kupon velja za izdelke z ean kodo: 9000100217199, 9000100212274 9000100212359, 9000100383370 9000100383417 9000100383455 9000100558693 9000100827713 9000100996341</p> </div> <p style="font-size: 8px; text-align: right;">2 090003 223887</p>	<p>Kupon velja v trgovinah in franšizah Tuš od 3. 2. do 16. 2. 2016 oz. do odprodaje zalog v tem obdobju. Unovčljiv je ob predložitvi Tuš klub kartice ob enkratnem nakupu enega ali do največ 6, enakih ali različnih, na kuponu navedenih izdelkov. Velja za količine, običajne za gospodinjске nakupe. Ne velja v Tuš drogerijah, Tuš Cash&Carry, za akcijske izdelke, na odložena plačila in za pravne osebe. Popusti se ne seštevajo.</p> <div style="display: flex; align-items: center;"> <p style="font-size: 8px;">Kupon velja za izdelke z ean kodo: 9000100762571, 9000100886628, 9000100967938, 9000100968379</p> </div> <p style="font-size: 8px; text-align: right;">2 090003 223870</p>	<p>Kupon velja v trgovinah in franšizah Tuš od 3. 2. do 16. 2. 2016 oz. do odprodaje zalog v tem obdobju. Unovčljiv je ob predložitvi Tuš klub kartice ob enkratnem nakupu enega ali do največ 6, enakih ali različnih, na kuponu navedenih izdelkov. Velja za količine, običajne za gospodinjске nakupe. Ne velja v Tuš drogerijah, Tuš Cash&Carry, za akcijske izdelke, na odložena plačila in za pravne osebe. Popusti se ne seštevajo.</p> <div style="display: flex; align-items: center;"> <p style="font-size: 8px;">Kupon velja za izdelke z ean kodo: 900010078824, 900010079357, 9000100939911, 9000100940861, 9000100941095, 9000100995951 9000100997979, 9000100961271, 9000101018356, 9000100778494 9000100778821 9000100939913 9000100960106 9000100962070</p> </div> <p style="font-size: 8px; text-align: right;">2 090003 223863</p>
<p>Kupon velja v trgovinah in franšizah Tuš od 3. 2. do 16. 2. 2016 oz. do odprodaje zalog v tem obdobju. Unovčljiv je ob predložitvi Tuš klub kartice ob enkratnem nakupu enega ali do največ 6, enakih ali različnih, na kuponu navedenih izdelkov. Velja za količine, običajne za gospodinjске nakupe. Ne velja v Tuš drogerijah, Tuš Cash&Carry, za akcijske izdelke, na odložena plačila in za pravne osebe. Popusti se ne seštevajo.</p> <div style="display: flex; align-items: center;"> <p style="font-size: 8px;">Kupon velja za izdelke z ean kodo: 9000100663809, 9000100833080, 9000100902717, 9000100930628, 9000100960786, 9000100971508</p> </div> <p style="font-size: 8px; text-align: right;">2 090003 223917</p>	<p>Kupon velja v trgovinah in franšizah Tuš od 3. 2. do 16. 2. 2016 oz. do odprodaje zalog v tem obdobju. Unovčljiv je ob predložitvi Tuš klub kartice ob enkratnem nakupu enega ali do največ 6, enakih ali različnih, na kuponu navedenih izdelkov. Velja za količine, običajne za gospodinjске nakupe. Ne velja v Tuš drogerijah, Tuš Cash&Carry, za akcijske izdelke, na odložena plačila in za pravne osebe. Popusti se ne seštevajo.</p> <div style="display: flex; align-items: center;"> <p style="font-size: 8px;">Kupon velja za izdelke z ean kodo: 9000100982245, 90005862, 90005879, 90407208, 90407215 90407222, 90005886</p> </div> <p style="font-size: 8px; text-align: right;">2 090003 223900</p>	<p>Kupon velja v trgovinah in franšizah Tuš od 3. 2. do 16. 2. 2016 oz. do odprodaje zalog v tem obdobju. Unovčljiv je ob predložitvi Tuš klub kartice ob enkratnem nakupu enega ali do največ 6, enakih ali različnih, na kuponu navedenih izdelkov. Velja za količine, običajne za gospodinjске nakupe. Ne velja v Tuš drogerijah, Tuš Cash&Carry, za akcijske izdelke, na odložena plačila in za pravne osebe. Popusti se ne seštevajo.</p> <div style="display: flex; align-items: center;"> <p style="font-size: 8px;">Kupon velja za izdelke z ean kodo: 9000100388559, 9000100388634 9000100388757, 9000100388795 900010025449, 9000100801652 9000100821469 9000100929189 9000100929394 9000100558349 9000101013368</p> </div> <p style="font-size: 8px; text-align: right;">2 090003 223894</p>
<p>Kupon velja v trgovinah in franšizah Tuš od 3. 2. do 16. 2. 2016 oz. do odprodaje zalog v tem obdobju. Unovčljiv je ob predložitvi Tuš klub kartice ob enkratnem nakupu enega ali do največ 6, enakih ali različnih, na kuponu navedenih izdelkov. Velja za količine, običajne za gospodinjске nakupe. Ne velja v Tuš drogerijah, Tuš Cash&Carry, za akcijske izdelke, na odložena plačila in za pravne osebe. Popusti se ne seštevajo.</p> <div style="display: flex; align-items: center;"> <p style="font-size: 8px;">Kupon velja za izdelke z ean kodo: 9000100868082, 9000100868242</p> </div> <p style="font-size: 8px; text-align: right;">2 090003 223948</p>	<p>Kupon velja v trgovinah in franšizah Tuš od 3. 2. do 16. 2. 2016 oz. do odprodaje zalog v tem obdobju. Unovčljiv je ob predložitvi Tuš klub kartice ob enkratnem nakupu enega ali do največ 6, enakih ali različnih, na kuponu navedenih izdelkov. Velja za količine, običajne za gospodinjске nakupe. Ne velja v Tuš drogerijah, Tuš Cash&Carry, za akcijske izdelke, na odložena plačila in za pravne osebe. Popusti se ne seštevajo.</p> <div style="display: flex; align-items: center;"> <p style="font-size: 8px;">Kupon velja za izdelke z ean kodo: 9000100407402, 9000100545140, 9000100542036, 9000100627074, 9000100822104, 9000100868081, 9000100868182, 9000100868243, 9000100868441, 9000100868452, 9000100868463, 9000100868464, 9000100868465, 9000100868466, 9000100868467, 9000100868468, 9000100868469, 9000100868470, 9000100868471, 9000100868472, 9000100868473, 9000100868474, 9000100868475, 9000100868476, 9000100868477, 9000100868478, 9000100868479, 9000100868480, 9000100868481, 9000100868482, 9000100868483, 9000100868484, 9000100868485, 9000100868486, 9000100868487, 9000100868488, 9000100868489, 9000100868490, 9000100868491, 9000100868492, 9000100868493, 9000100868494, 9000100868495, 9000100868496, 9000100868497, 9000100868498, 9000100868499, 9000100868500</p> </div> <p style="font-size: 8px; text-align: right;">2 090003 223931</p>	<p>Kupon velja v trgovinah in franšizah Tuš od 3. 2. do 16. 2. 2016 oz. do odprodaje zalog v tem obdobju. Unovčljiv je ob predložitvi Tuš klub kartice ob enkratnem nakupu enega ali do največ 6, enakih ali različnih, na kuponu navedenih izdelkov. Velja za količine, običajne za gospodinjске nakupe. Ne velja v Tuš drogerijah, Tuš Cash&Carry, za akcijske izdelke, na odložena plačila in za pravne osebe. Popusti se ne seštevajo.</p> <div style="display: flex; align-items: center;"> <p style="font-size: 8px;">Kupon velja za izdelke z ean kodo: 4015000301039, 9000100147293 9000100344098, 900033714</p> </div> <p style="font-size: 8px; text-align: right;">2 090003 223924</p>

PRILOGA E: Priporočila artiklov za primer personalizirane direktne pošte

Tabela E.1: Primer priporočil za blagovno skupino MEHČALCI PERILA.

Priporočilo	Izboljšava	Podpora	Zaupanje
NAZIV_BS_PRALNI_PRAŠKI - KAPSULE	6,5	0,3 %	27,8 %
NAZIV_BS_PRALNI_PRAŠKI - PRAH	6,2	1,8 %	26,2 %
NAZIV_BS_PRALNI_PRAŠKI-GELI,TEKOČ.	5,9	1,3 %	24,9 %
NAZIV_BS_DETERG.ZA_OBČUTLJ.PERILO	5,5	0,6 %	23,2 %
NAZIV_BS_ODSTRANJEVALCI MADEŽEV	4,7	0,5 %	19,8 %
NAZIV_BS_SREDS.ZA_PREPRE_VOD.KAMNA	4,4	0,1 %	18,7 %
NAZIV_BS_ČISTILA - KOPALNICE	4,0	0,2 %	17,2 %
NAZIV_BS_ČISTILA - KUHINJA	3,9	0,5 %	16,4 %
NAZIV_BS_BELILA, APRETURE, ŠTIRKE	3,8	0,3 %	16,2 %
NAZIV_BS_DETER.STR.POM.POS-TABLETE	3,7	0,5 %	15,8 %
NAZIV_BS_WC_OBEŠANKE - GELI	3,6	0,3 %	15,4 %
NAZIV_BS_ČISTILA - UNIVERZALNA	3,6	1,3 %	15,3 %
NAZIV_BS_OSVEŽILCI PROST.-ELEKTRIC	3,6	0,2 %	15,2 %
NAZIV_BS_ČISTILA - STEKLO	3,6	0,6 %	15,1 %
NAZIV_BS_ČISTILA ZA WC	3,5	0,7 %	14,9 %
NAZIV_BS_WC_OBEŠANKE - TRDE	3,5	1,2 %	14,7 %
NAZIV_BS_DETER.STR.POM.POS-GEL	3,5	0,2 %	14,7 %
NAZIV_BS_PENEČE KOPELI IN SOLI	3,3	0,3 %	13,8 %
NAZIV_BS_WC_OBEŠANKE - TEKOČE	3,2	0,8 %	13,7 %
NAZIV_BS_DETER.ZA ROČNO POM.POSODE	3,2	3,7 %	13,5 %
NAZIV_BS_DETER.STR.POM.POS-SOLI	3,2	0,4 %	13,5 %
NAZIV_BS_ČISTILA - VODNI KAMEN	3,2	0,1 %	13,4 %
NAZIV_BS_ČISTILA - LES, PRAH	3,2	0,1 %	13,4 %
NAZIV_BS_DESTILIRANA VODA	3,1	0,4 %	13,3 %
NAZIV_BS_DETER.STR.POM.POS-SIJAJ	3,1	0,2 %	13,3 %
NAZIV_BS_OSVEŽILCI PROST.-KLIK SP.	3,1	0,1 %	13,2 %
NAZIV_BS_ČISTILA - TALNE POVRŠINE	3,1	0,1 %	13,1 %
NAZIV_BS_OTROŠKI ŠAMPONI, BALZAMI	3,1	0,2 %	13,0 %
NAZIV_BS_DEODORANTI -STICK ŽENSKI	3,1	0,1 %	13,0 %
NAZIV_BS_TUŠ GELI	3,1	1,1 %	13,0 %
NAZIV_BS_KRPE, GOBE - ŽIČNE, VOLNA	3,0	0,4 %	12,8 %
NAZIV_BS_BALZAMI ZA LASE	3,0	0,5 %	12,8 %

Tabela E.2: Primer priporočil za blagovno skupino DETERGENTI ZA ROČNO POMIVANJE POSODE.

Priporočilo	Izboljšava	Podpora	Zaupanje
NAZIV_BS_KRPE, GOBE - ŽIČNE, VOLNA	5,2	0,4 %	19,2 %
NAZIV_BS_ČISTILA ZA WC	4,9	0,7 %	18,1 %
NAZIV_BS_ČISTILA - KUHINJA	4,9	0,5 %	18,0 %
NAZIV_BS_KRPE, GOBE - GOSPODINJSKE	4,7	1,8 %	17,2 %
NAZIV_BS_ČISTILA - UNIVERZALNA	4,6	1,3 %	17,0 %
NAZIV_BS_ČISTILA - VODNI KAMEN	4,6	0,1 %	17,0 %
NAZIV_BS_ČISTILA - KOPALNICE	4,5	0,2 %	16,7 %
NAZIV_BS_ČISTILA - STEKLO	4,5	0,6 %	16,5 %
NAZIV_BS_ČISTILA - LES, PRAH	4,0	0,1 %	14,9 %
NAZIV_BS_ČISTILA - TALNE POVRŠINE	4,0	0,1 %	14,8 %
NAZIV_BS_MILO TOALETNO	4,0	0,8 %	14,8 %
NAZIV_BS_SREDS.ZA PREPRE VOD.KAMNA	3,9	0,1 %	14,5 %
NAZIV_BS_DETER.STR.POM.POS-SIJAJ	3,8	0,2 %	13,9 %
NAZIV_BS_WC OBEŠANKE - GELI	3,8	0,3 %	13,9 %
NAZIV_BS_PRALNI PRAŠKI - PRAH	3,8	1,8 %	13,8 %
NAZIV_BS_WC OBEŠANKE - TEKOČE	3,7	0,8 %	13,6 %
NAZIV_BS_DETER.STR.POM.POS-GEL	3,7	0,2 %	13,6 %
NAZIV_BS_OSVEŽILCI PROST.-KLIK SP.	3,6	0,1 %	13,2 %
NAZIV_BS_MILO TEKOČE	3,5	0,8 %	12,9 %
NAZIV_BS_DETER.STR.POM.POS-SOLI	3,5	0,4 %	12,8 %
NAZIV_BS_DETER.STR.POM.POS-TABLETE	3,4	0,5 %	12,7 %
NAZIV_BS_DODATKI JEDEM KOZARČKI	3,4	0,1 %	12,5 %
NAZIV_BS_KAVOVINE	3,4	0,7 %	12,4 %
NAZIV_BS_BELILA, APRETURE, ŠTIRKE	3,3	0,3 %	12,2 %
NAZIV_BS_ODSTRANJEVALCI MADEŽEV	3,2	0,5 %	11,9 %
NAZIV_BS_DETERG.ZA OBČUTLJ.PERILO	3,2	0,6 %	11,9 %
NAZIV_BS_MEHČALCI PERILA	3,2	4,3 %	11,7 %
NAZIV_BS_OSVEŽILCI PROST.-SPREJI	3,2	0,2 %	11,7 %
NAZIV_BS_RIŽ OSNOVNI	3,2	2,7 %	11,7 %
NAZIV_BS_OLJE SOLATNO	3,2	0,9 %	11,7 %
NAZIV_BS_WC OBEŠANKE - TRDE	3,2	1,2 %	11,7 %
NAZIV_BS_SOL	3,1	2,9 %	11,5 %
NAZIV_BS_PRALNI PRAŠKI-GELI,TEKOČ.	3,1	1,3 %	11,5 %
NAZIV_BS_PRALNI PRAŠKI - KAPSULE	3,1	0,3 %	11,4 %
NAZIV_BS_MILO INTIMNO	3,1	0,1 %	11,4 %
NAZIV_BS_PENEČE KOPELI IN SOLI	3,1	0,3 %	11,3 %
NAZIV_BS_JUHE INSTANT KOCKE	3,0	1,9 %	11,2 %
NAZIV_BS_ŠAMPONI	3,0	1,8 %	11,2 %
NAZIV_BS_OLJE RASTLINSKO	3,0	2,8 %	11,1 %
NAZIV_BS_BRISAČE PAPIRNATE	3,0	3,9 %	11,0 %
NAZIV_BS_TESTENINE DOLGE	3,0	1,3 %	11,0 %
NAZIV_BS_BALZAMI ZA LASE	3,0	0,5 %	10,9 %
NAZIV_BS_TUŠ GELI	3,0	1,1 %	10,9 %

Tabela E.3: Primer priporočil za blagovno skupino PRALNI PRAŠKI ter DETEREGENTI ZA OBČUTLJIVO PERILO.

Priporočilo	Izboljšava	Podpora	Zaupanje
NAZIV_BS_ODSTRANJEVALCI MADEŽEV	9,2	0,5 %	5,5 %
NAZIV_BS_SREDS.ZA PREPRE VOD.KAMNA	6,7	0,1 %	12,3 %
NAZIV_BS_ODSTRANJEVALCI MADEŽEV	6,3	0,5 %	8,2 %
NAZIV_BS_MEHČALCI PERILA	6,2	4,3 %	11,4 %
NAZIV_BS_DETER.STR.POM.POS-TABLETE	6,0	0,5 %	7,7 %
NAZIV_BS_MEHČALCI PERILA	5,9	4,3 %	7,6 %
NAZIV_BS_SREDS.ZA PREPRE VOD.KAMNA	5,3	0,1 %	6,9 %
NAZIV_BS_BELILA, APRETURE, ŠTIRKE	5,2	0,3 %	6,7 %
NAZIV_BS_DETER.STR.POM.POS-TABLETE	5,0	0,5 %	9,2 %
NAZIV_BS_ODSTRANJEVALCI MADEŽEV	4,9	0,5 %	9,0 %
NAZIV_BS_DETER.STR.POM.POS-GEL	4,6	0,2 %	6,0 %
NAZIV_BS_ČISTILA ZA WC	4,6	0,7 %	8,5 %
NAZIV_BS_ČISTILA - VODNI KAMEN	4,6	0,1 %	5,9 %
NAZIV_BS_ČISTILA ZA WC	4,2	0,7 %	5,4 %
NAZIV_BS_ČISTILA - VODNI KAMEN	4,2	0,1 %	7,7 %
NAZIV_BS_ČISTILA - KUHINJA	4,1	0,5 %	7,6 %
NAZIV_BS_ČISTILA - UNIVERZALNA	4,1	1,3 %	5,3 %
NAZIV_BS_ČISTILA - LES, PRAH	4,1	0,1 %	7,5 %
NAZIV_BS_PENEČE KOPELI IN SOLI	4,1	0,3 %	7,5 %
NAZIV_BS_KRPE, GOBE - ŽIČNE, VOLNA	4,0	0,4 %	7,4 %
NAZIV_BS_OSVEŽILCI PROST.-ELEKTRIČ	4,0	0,2 %	5,2 %
NAZIV_BS_DETER.STR.POM.POS-SIJAJ	3,9	0,2 %	7,2 %
NAZIV_BS_WC OBEŠANKE - TRDE	3,9	1,2 %	5,0 %
NAZIV_BS_ČISTILA - UNIVERZALNA	3,8	1,3 %	7,1 %
NAZIV_BS_WC OBEŠANKE - TRDE	3,8	1,2 %	7,0 %
NAZIV_BS_DETER.ZA ROČNO POM.POSODE	3,8	3,7 %	6,9 %
NAZIV_BS_ČISTILA - STEKLO	3,7	0,6 %	6,9 %
NAZIV_BS_MILO TOALETNO	3,7	0,8 %	6,8 %
NAZIV_BS_DETER.STR.POM.POS-SOLI	3,6	0,4 %	6,6 %
NAZIV_BS_WC OBEŠANKE - TEKOČE	3,4	0,8 %	6,3 %
NAZIV_BS_ČISTILA - TALNE POVRŠINE	3,4	0,1 %	6,3 %
NAZIV_BS_PENE ZA LASE	3,4	0,1 %	6,2 %
NAZIV_BS_WC OBEŠANKE - GELI	3,3	0,3 %	6,1 %
NAZIV_BS_DETER.STR.POM.POS-GEL	3,3	0,2 %	6,1 %
NAZIV_BS_BELILA, APRETURE, ŠTIRKE	3,3	0,3 %	6,0 %
NAZIV_BS_IZDELKI PROTETIKE	3,2	0,2 %	5,9 %
NAZIV_BS_KRPE, GOBE - GOSPODINJSKE	3,2	1,8 %	5,9 %
NAZIV_BS_DESTILIRANA VODA	3,2	0,4 %	5,9 %
NAZIV_BS_OSVEŽILCI PROST.-ELEKTRIČ	3,1	0,2 %	5,7 %
NAZIV_BS_OLJE SOLATNO	3,1	0,9 %	5,7 %
NAZIV_BS_ČISTILA - KOPALNICE	3,0	0,2 %	5,6 %
NAZIV_BS_LAKI ZA LASE	3,0	0,7 %	5,5 %
NAZIV_BS_OTROŠKI ŠAMPONI, BALZAMI	3,0	0,2 %	5,4 %

PRILOGA F: Potrošniški trendi za leto 2016

Tabela F.1: 10 potrošniških trendov za leto 2016 (Euromonitor International).

Deset najizrazitejših potrošniških trendov v letu 2016	
Agnostični kupci	Privlači jih inovativnost glede cene, trajna privlačnost varčnega nakupovanja, ljubezen do popustov in popolna ljubezen, recesije povečujejo podučenost, nakupujejo lokalno.
Kupovanje časa	Nove rešitve za časovne prihranke za časovno omejeno mestno življenje, atletske – prostočasne: vedno pripravljene za rekreacijo, podpora kupcem v realnem času, prodajanje spanca.
Izziv staranja	Razdvojen segment potrošnikov post srednjih let, energijsko polno staranje, napredni stil, digitalna vključenost.
Nosilci sprememb	Nosilci socialnih gibanj, majhni donatorji, skrb vzornikov, manjši poudarek na kopičenju, pridobivanju lastnine.
Mešanje spolov	Spolni non-konformizem, ne-možače, blagovne znamke spolno odprtih dobrin in nova podoba trgovin, starši in kritiki spolnega stereotipiziranja postajajo vse glasnejši, androgen stil.
Bolj zelena hrana	Konec zavrnjenju hrane, lokavorizem: uživati lokalno, tradicionalne tržnice, varnejša, hitrejša hrana.
Duševno zdravje	Potrošnja ne zadeva zgolj stvari, biti, ne biti izgorel, zavedanje drugih, vzvratni udarec zavedanja.
Pretirano povezani potrošniki	Mobilna ljubezen je zakon, vendar je lahko toksična, vampirski otroci, več zdravstvenih slabosti kot digitalno življenje, vzeti si digitalni odmor.
Nakupovanje za nadzor	Zaskrbljeno starševstvo in zaporniško življenje v družbi, pametno življenje za zmanjšano ranljivost, kupovanje nadzora, nihanje med svobodo in varnostjo.
Zapravljive samske osebe	Solo potovanja, zapeljivi potrošniki, ki jih pritegne avtentičnost, zapravljivci brez otrok, mladi urbani kreativci.

Vir: Daphne 2016.