

UNIVERZA V LJUBLJANI
FAKULTETA ZA RAČUNALNIŠTVO IN INFORMATIKO

Damjan Kosec

**UPORABA PRIPOROČILNIH IN ODLOČITVENIH
SISTEMOV ZA PERSONALIZACIJO PRODAJE V
MOBILNI APLIKACIJI**

MAGISTRSKO DELO

MAGISTRSKI PROGRAM
INFORMACIJSKI SISTEMI IN ODLOČANJE

Mentor: doc. dr. Rok Rupnik

Ljubljana, 2016



Številka: 143-MAG-ISO/2016

Datum: 29. 02. 2016

Damjan KOSEC, univ. dip. org.

Ljubljana

Fakulteta za računalništvo in informatiko Univerze v Ljubljani izdaja naslednjo magistrsko nalogo

Naslov naloge: **Uporaba priporočilnih in odločitvenih sistemov za personalizacijo prodaje v mobilni aplikaciji**

The use of recommendation systems and decision support systems for sales personalization in mobile application

Tematika naloge:

Velika količina informacij ter široka ponudba produktov in storitev, danes kupcu onemogoča racionalno odločitev glede nakupa tistih produktov in storitev, ki jih ta dejansko potrebuje v določenem času in kraju, glede na svoje želje, interese in potrebe. Podjetja se prav tako soočajo s pomanjkanjem kvalitetnih informacij o svojih kupcih, njihovih navadah, prihodnjih nakupih, preteklih izkušnjah in zato nimajo vseh odgovorov na pomembna vprašanja, ki se tičejo marketinga, prodaje in poslovanja podjetja v realnem času.

S pomočjo priporočilnih in odločitvenih sistemov in obdelave velike količine pametnih podatkov lahko kupcu ponudimo personalizirane produkte in storitve ter s tem pospešujemo in povečujemo prodajo ter na drugi strani izboljšujemo uporabniško in nakupovalno izkušnjo. Zaradi narave mobilnih naprav, lahko danes od uporabnikov pridobimo kontekstualne informacije, njihove lastnosti in druge pomembne informacije, ki jih uporabimo v priporočilnih sistemih.

V magistrski nalogi preglejte različne tipe, principe, metode ter pristope glede uporabe in evalvacije priporočilnih in odločitvenih modelov. Proučite prednosti in slabosti uporabe različnih tipov in metod priporočilnih sistemov ter možnosti uporabe na področju marketinga in prodaje. Po pregledu in analizi izberite primerni model priporočilnega sistema za pospeševanje prodaje in izdelajte praktično rešitev z razvojem informacijskega sistema in mobilne aplikacije za personalizacijo prodaje.

Mentor:

doc. dr. Rok Rupnik



Dekan:

prof. dr. Nikolaj Zimic

IZJAVA O AVTORSTVU

magistrskega dela

Spodaj podpisani/-a Damjan Kosec,

z vpisno številko 63030381,

sem avtor/-ica magistrskega dela z naslovom

UPORABA PRIPOROČILNIH IN ODLOČITVENIH SISTEMOV ZA PERSONALIZACIJO
PRODAJE V MOBILNI APLIKACIJI

S svojim podpisom zagotavljam, da:

- sem magistrsko delo izdelal/-a samostojno pod vodstvom mentorja (naziv, ime in priimek)

doc. dr. Rok Rupnik

in somentorstvom (naziv, ime in priimek)

- so elektronska oblika magistrskega dela, naslova (slov., angl.), povzetka (slov., angl.) ter ključne besede (slov., angl.) identični s tiskano obliko magistrskega dela
- in soglašam z javno objavo elektronske oblike magistrskega dela v zbirki »Dela FRI«.

V Ljubljani, dne 10.8.2016

Podpis avtorja/-ice: 

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

Zahvala

Zahvalil bi se rad vsem, ki so kakorkoli pripomogli k izvedbi tega magistrskega dela, še posebej mentorju doc. dr. Roku Rupniku za mentorstvo, pomoč, ideje in nasvete.

Še posebej bi se rad zahvalil vsem podjetjem in medijem, ki so podprli idejo in razvito rešitev ter pristopili k poslovnemu sodelovanju. Vaš doprinos mi je dal dodatno motivacijo.

Kazalo vsebine

Povzetek.....	1
Abstract.....	2
1. Uvod.....	3
1.1 Pregled strukture magistrske naloge.....	4
2. Sorodne raziskave	6
3. Priporočilni sistemi in sistemi za podporo odločanju	8
3.1 Priporočilni sistemi	8
3.2 Zgodovina priporočilnih sistemov	9
3.3 Priporočilne tehnike	9
3.4 Uporaba priporočilnih sistemov.....	21
3.5 Faze priporočilnega procesa	22
3.6 Metrike vrednotenja priporočilnih sistemov	24
3.7 Kvaliteta priporočilnih sistemov	26
3.8 Trendi priporočilnih sistemov.....	26
3.9 Proces rudarjenja podatkov.....	28
3.10 Gradnja uporabniškega modela.....	31
3.11 Sistemi za podporo odločanju	34
3.12 Poslovna analitika	37
3.13 Strojno učenje	37
3.14 Apache Hadoop.....	38
4. Digitalni marketing v obdobju Big Data in interneta stvari IoT	42
4.1 Dimenzije in karakteristike Big Data.....	43
4.2 Big Data Analitika	45
4.3 Marketinška analitika.....	51
4.4 Internet stvari IoT	51
5 Uporaba personalizacije za pospeševanje prodaje	57
5.1 E-trgovanje in m-trgovanje	57
5.2 1-1 marketing.....	57
5.3 Zasebnost	57
5.4 Vedenjsko raziskovanje	59
5.5 Personalizacija	62
6 Razvoj priporočilnega in odločitvenega sistema ter mobilne aplikacije za personalizacijo prodaje QuickA	70
6.1 Načrtovanje in razvoj priporočilnega in odločitvenega sistema.....	74
6.2 Sistemska analiza in planiranje.....	74

6.3	Načrtovanje sistema.....	80
6.4	Razvoj informacijskega in priporočilnega sistema.....	81
6.5	Funkcionalnosti informacijskega in priporočilnega sistema.....	82
6.6	Mobilna aplikacija QuickA.....	98
6.7	Testiranje informacijskega in priporočilnega sistema.....	119
6.8	Implementacija in vzdrževanje.....	120
7	Analiza odločitvenega in priporočilnega modela ter praktična uporaba.....	121
8	Zaključek.....	125
	Seznam slik.....	126
	Seznam enačb.....	128
	Literatura in viri.....	129

Seznam kratic

AIS	Artificial immune system (slov. umetno imunski sistem)
ANN	Artificial neural network (slov. umetna nevrnska omrežja)
API	Application programming interface (slov. aplikacijski programski vmesnik)
ASR	Automatic speech recognition (slov. avtomatska prepoznavna govora)
BPM	Business performance measurement (slov. merjenje poslovne uspešnosti)
CSS	Cascading Style Sheets
CB	Content based Filtering (slov. vsebinsko filtriranje)
CBR	Case based reasoning (slov. obrazložitev na primeru)
CCTV	Closed circuit television
CERP	Cluster of European Research Projects
CF	Collaborative Filtering (slov. skupinsko filtriranje)
CRISP	Cross Industry Standard Process
CRM	Customer Relationship Management (slov. upravljanje odnosov s strankami)
CTR	Click to rate
DSS	Decision support system (slov. sistemi za podporo odločanju)
ERP	Enterprise resource planning (slov. sistemi za upravljanje resursov)
ER	Entity Recognition (slov. prepoznavanje entitete)
FTC	Federal Trade Commission (slov. ameriška trgovinska zbornica)
GA	Genetic Algorithms (slov. genetski algoritmi)
GFS	Google File System (slov. Googlov datotečni sistem)
GIS	Geographical information system (slov. geografski informacijski sistemi)
GSM	Global System for Mobile communications
GPS	Global Positioning System (slov. globalni sistem pozicioniranja)
GRS	Group recommendation system (slov. skupinski priporočilni sistemi)
HCA	Hierarchical criteria architecture (slov. hierarhična arhitektura kriterijev)
HDFS	Hadoop Distributed File System (slov. distribuirani datotečni sistem Hadoop)
HITS	Hyperlink Induced Topic Search
HTML	Hyper Text Markup Language
IoT	Internet of Things (slov. internet stvari)
IP	Internet Protocol (slov. internetni protokol)
IR	Information retrieval (slov. pridobivanje informacij)
JSON	JavaScript Object Notation
KB	Knowledge based Filtering (slov. filtriranje s pomočjo baze znanja)
LAS	Location based services (slov. lokacijsko osnovane storitve)
MAE	Mean Absolute Error (slov. srednja absolutna napaka)
NLP	Advanced Natural Language Processing (slov. napredno procesiranje naravnega jezika)
NN	Neural Networks (slov. nevrnska omrežja)
PDF	Portable Document Format (slov. prenosni dokumentni format)
POS	Point of sale (slov. točka prodaje)
PRC	Precision Recall Curve (slov. krivulja odpoklica točnosti)
QA	Question answering (slov. odgovori na vprašanja)
QR	Quick Response
RE	Relation Extraction (slov. izvlečenje razmerij)
ROI	Return on investment (slov. vračilo investicije)
RFID	Radio Frequency Identification (slov. radio frekvenčna identifikacija)
RMSE	Root Mean Square Error (slov. zgornja srednja kvadratna napaka)

ROC Receiver Operating Characteristics (slov. operativne značilnosti sprejemnika)
SMS Short Message Service (slov. kratka sporočila)
SNA Social Network Analysis (slov. analiza družbenih omrežij)
SQL Structured Query Language (slov. strukturirani povpraševalni jezik)
SVD Singular Value Decomposition (slov. razgradnja ene vrednosti)
TB Tera Byte
URL Uniform Resource Locator (slov. enolični krajevnik vira)
VCA Video content analysis (slov. analiza video vsebine)
WOM Word of mouth (slov. od ust do ust)
WSN Wireless sensor networks (slov. omrežja brezžičnih senzorjev)

Povzetek

Uporabniki se dandanes v nakupovalnem procesu soočajo z veliko količino informacij ter široko ponudbo produktov in storitev, kar kupcu onemogoča racionalno odločitev o nakupu tistih produktov in storitev, ki jih dejansko potrebuje v določenem času in kraju, in sicer glede na svoje želje, interese in potrebe.

Z definiranjem in potrditvijo problema pri uporabnikih smo se lotili analize, načrtovanja, razvoja, testiranja in implementacije informacijskega in priporočilnega sistema za personalizacijo prodaje.

Informacijski sistem deluje na poslovnem modelu, ki uporabniku za posredovanje pomembnih povratnih informacij v zameno ponudi akcijske ponudbe ali točke zvestobe. Pomanjkanje kvalitetnih informacij o kupcih, njihovih navadah, prihodnjih nakupih in preteklih izkušnjah je eden od ključnih razlogov, da podjetja ne morejo izvajati učinkovite personalizacije. Tako tudi v realnem času nimajo vseh odgovorov na pomembna vprašanja, ki se tičejo marketinga, prodaje in poslovanja podjetja.

S pomočjo priporočilnih in odločitvenih sistemov in obdelave velike količine pametnih podatkov lahko kupcu ponudimo personalizirane produkte in storitve ter s tem pospešujemo in povečujemo prodajo, na drugi strani pa izboljšujemo uporabniško ter nakupovalno izkušnjo. Pri analizi in razvoju informacijskega in priporočilnega sistema smo postavili hipotezo, da bomo lahko z uporabo kvalitetnih podatkov o uporabnikovih željah, potrebah, preteklih izkušnjah in prihodnjih nakupih uporabniku ponudili veliko bolj personalizirane akcijske ponudbe. S personalizacijo bomo zelo povečali konverzijo CTR (angl. click to rate) med ogledi akcijskih ponudb in odgovori oziroma izvedbo prodajnih akcij.

Na podlagi izdelanega in preizkušenega priporočilnega sistema sklepamo, da je za našo rešitev najprimernejša uporaba hibridnih priporočilnih tehnik, kjer se glede na različne situacije uporabita metodi filtriranja CF ali CB v kombinaciji z ostalimi odločitvenimi pravili in pogoji.

Ključne besede: priporočilni sistemi, skupinsko filtriranje CF, vsebinsko filtriranje CB, Big Data, Internet stvari IoT, personalizacija

Abstract

In the process of shopping, users are today faced with a large volume of information and a broad range of products and services that prevent them from being able to make rational decisions regarding the purchase of those products and services they actually require at a particular time and place and which meet their preferences, interests and needs.

By defining and confirming this problem faced by users, we began with the analysis, design, development, testing and implementation of an information and recommendation system for the personalization of sales.

This information system operates on the basis of a business model, where in exchange for providing important feedback, the user receives special offers or loyalty points. A lack of qualitative data about customers, their habits, future purchases and past experiences is one of the key factors in preventing companies from implementing effective personalization. Thus, even in real time, companies lack answers to important questions that concern marketing, sales and business operations.

With the assistance of recommendation and decision making systems and by processing large amounts of smart data, we can offer the customer personalized products and services and thereby accelerate and increase sales volume while simultaneously improving the user and shopping experience. In the analysis and development of the information and recommendation system, we developed a hypothesis which proposed that with the use of qualitative data on user desires, needs, past experiences and future purchases, we could offer the user more personalized special offers. Personalization will also enable an increase of the CTR (Click to Rate) conversion between views of special offers and relevant responses, or rather, the execution of sales campaigns.

On the basis of the developed and tested recommendation system, we conclude that the most appropriate solution for our purposes is the use of hybrid recommendation techniques which, depending on different types of situations, implement either the CF or CB method of filtering in combination with other decision rules and conditions.

Keywords: recommendation systems, CF collaborative filtering, CB content filtering, Big Data, Internet of Things IoT, personalization

1. Uvod

Velika količina informacij ter široka ponudba produktov in storitev danes kupcu onemogočajo racionalno odločitev glede nakupa tistih produktov in storitev, ki jih ta dejansko potrebuje v določenem času in kraju glede na svoje želje, interese in potrebe. Podjetja se prav tako soočajo s pomanjkanjem kvalitetnih informacij o svojih kupcih, njihovih navadah, prihodnjih nakupih, preteklih izkušnjah in zato v realnem času nimajo vseh odgovorov na pomembna vprašanja, ki se tičejo marketinga, prodaje in poslovanja podjetja.

S pomočjo priporočilnih in odločitvenih sistemov ter obdelave velike količine pametnih podatkov lahko kupcu ponudimo personalizirane produkte in storitve ter s tem pospešujemo in povečujemo prodajo, na drugi strani pa izboljšujemo uporabniško in nakupovalno izkušnjo. Zaradi narave mobilnih naprav lahko danes od uporabnikov pridobimo kontekstualne informacije, njihove želje, lastnosti in druge pomembne informacije, ki jih uporabimo za personalizacijo v priporočilnih sistemih [24].

Za cilj v magistrski nalogi sem si zadal teoretični pregled različnih tipov, principov, metod ter pristopov o uporabi in evalvaciji priporočilnih in odločitvenih modelov. Preučil sem prednosti in slabosti uporabe različnih tipov in metod priporočilnih sistemov ter možnosti uporabe priporočilnih sistemov na področju marketinga in prodaje. Po pregledu in analizi sem izbral primerni model priporočilnega sistema za pospeševanje prodaje in izdelal praktično rešitev z razvojem informacijskega in priporočilnega sistema ter mobilne aplikacije za personalizacijo prodaje. Skupni cilj magistrske naloge je tako bil združitev teoretičnega znanja z razvojem praktične rešitve priporočilnega sistema, ki rešuje praktične probleme na trgu.

Priporočilni sistemi so spremenili način, kako ljudje danes iščejo ter najdejo produkte, storitve, informacije in tudi druge ljudi. Prav tako vedno večja količina informacij ter široka ponudba produktov in storitev danes kupcu onemogoča hitro in racionalno nakupno odločitev. Z uporabo priporočilnih sistemov lahko podjetja ponudijo personalizirana marketinška sporočila, produkte in storitve, pri čemer upoštevajo želje, interese in potrebe kupca, s tem pa pospešujejo in povečujejo prodajo ter zmanjšujejo stroške. Priporočilni sistemi so informacijski sistemi za filtriranje podatkov, ki se ukvarjajo s problemom prevelike količine informacij. Priporočilni sistemi filtrirajo pomembne in vitalne fragmente iz velike količine dinamično generiranih informacij o uporabnikovih lastnostih in interesih iz opazovanega in merjenega vedenja. Priporočilni sistemi imajo zmožnost predvidevanja, ali si določeni uporabnik določen produkt glede na svoj profil želi ali ne. Priporočilni sistemi so se izkazali za zelo koristne tudi pri odločitvenih procesih in izboljšanju kvalitete produktov ter celotnega poslovanja, zato je potreba po uporabi učinkovitih priporočilnih sistemov, ki bodo zagotavljali ustrezna in zanesljiva priporočila za uporabnike, nujna za uspešno poslovanje vsakega podjetja [11].

E-trgovanje je postalo pomemben poslovni model v 21. stoletju in ima pomemben vpliv na družbo, gospodarstvo, življenje in kulturo. Personalizirani priporočilni sistemi so ključna tehnologija v e-trgovanju, ki vpliva na rast prodaje in uspešnost poslovanja [30]. V številnih spletnih trgovinah lahko uporabnik izbira med velikim številom različnih produktov znotraj številnih kategorij. Čeprav bi se zdelo, da bo

povečana izbira boljša za zadovoljstvo uporabnika, je v večini primerov prav nasprotno. Ta fenomen je poznan kot paradoks izbire (angl. paradox of choice). Velik nabor možnosti otežuje uporabniku poiskati produkt, ki ga ima najraje, to je produkt, ki je najbolj podoben uporabnikovemu zamišljenemu idealnemu produktu [32].

Velika trgovska podjetja in tudi vse ostale gospodarske družbe, ki bodo hotele preživeti v 21. stoletju, bodo morale prilagoditi svoje poslovanje novim trendom ter poslovati globalno. Uporaba personalizacije ter komunikacije s kupcem ena na ena s pomočjo priporočilnih sistemov je ena od ključnih razvojnih prioritet za vsako podjetje [30].

1.1 Pregled strukture magistrske naloge

Struktura magistrske naloge je zgrajena iz začetnega teoretičnega dela in opisa razvoja praktične rešitve priporočilnega in odločitvenega sistema ter mobilne aplikacije za personalizacijo prodaje QuickA.

V uvodu magistrske naloge sem opisal ključne probleme, s katerimi se danes soočajo kupci. Velika količina informacij ter široka ponudba produktov in storitev danes kupcu onemogočajo racionalno odločitev glede nakupa tistih produktov in storitev, ki jih ta dejansko potrebuje v določenem času in kraju, upoštevajoč njegove želje, interese in potrebe.

V drugem poglavju sem opisal podobne raziskave s področja razvoja in uporabe priporočilnih sistemov na področju personalizacije za pospeševanje prodaje.

V tretjem poglavju sem raziskal literaturo in strokovne članke s področja priporočilnih sistemov in sistemov za podporo odločanju. V tem poglavju sem zajel celoten pogled in pregled priporočilnih sistemov od zgodovine priporočilnih sistemov, najpogostejših tehnik, ki se danes uporabljajo, uporabe priporočilnih sistemov, metrik vrednotenja priporočilnih sistemov, kvaliteto in trende na področju priporočilnih sistemov. Raziskal sem področje rudarjenja podatkov, poslovne inteligence in strojnega učenja. Preučil sem tudi trenutno najbolj vroče odprtodno ogrodje Hadoop, ki se uporablja za hranjenje in procesiranje Big Data podatkov. Hadoop in podobna ogrodja za distribuirano procesiranje, kot so Spark in Flink, so pridobila na veljavi in se danes uporabljajo že v številnih največjih podjetjih na svetu.

V četrtem poglavju sem raziskal področje digitalnega marketinga v obdobju Big Data in interneta stvari IoT. Opredelil sem dodano vrednost, ki jo prinaša Big Data na poslovanje podjetja in opisal pet ključnih dimenzij Big Data 5V (Volume, Velocity, Variety, Veracity, Value). Raziskal sem tudi področje Big Data analitike in ključne tehnike, kot so tekstovna analitika, avdio analitika, video analitika in analitika družbenih medijev. Na področju digitalnega marketinga bo v naslednjih letih prišlo do velikih sprememb, saj bo do leta 2020 v omrežje povezanih 26 milijard naprav. S tem namenom sem raziskal ključne tehnologije IoT, arhitekturo IoT, varnost in razvoj aplikacij IoT.

V petem poglavju sem raziskal področje personalizacije in vpliv personalizacije na prodajo. Marketing 1-1 danes podjetjem na trgu prinaša konkurenčno prednost in omogoča, da obdržijo obstoječe kupce in privabijo nove. Pri personalizaciji je zasebnost eno od ključnih področij pri načrtovanju priporočilnih sistemov, saj porušeno zaupanje uporabnika lahko vodi do izgube kupca. Ker naš informacijski sistem temelji na proaktivnem zbiranju osebnih podatkov, sem preučil področje vedenjskih raziskav, ki jih uporabljamo za izdelavo prodajnih akcij v našem

priporočilnem sistemu. Opisal sem tudi prednosti personalizacije, ključne dimenzije za implementacijo personalizacije in vrednotenje priporočilnih sistemov za personalizacijo.

V šestem poglavju sem opisal celoten razvojni cikel priporočilnega in odločitvenega sistema ter mobilne aplikacije za personalizacijo prodaje QuickA. S Quicko lahko uporabnik preko mobilne aplikacije ali spletne strani:

- izbere blagovno znamko ali podjetje,
- sodeluje z blagovno znamko ali podjetjem s hitrim odgovorom ali akcijo,
- prejme nagrado, akcijsko ponudbo ali program zvestobe.

S pomočjo mobilne aplikacije je naš priporočilni sistem pridobival pomembne podatke o uporabnikih, ki smo jih uporabili za personalizacijo prodajnih akcij. Uporabnik je v zameno za akcijske ponudbe ali točke zvestobe sodeloval v prodajni akciji z odgovorom na anketo, kviz, oceno produkta, primerjavo produkta, prenosom fotografije, prenosom videa, ogledom sporočila ali galerije. V tem poglavju je opisan celoten razvoj priporočilnega sistema in predstavitev spletnega portala in mobilne aplikacije ter algoritma za personalizacijo.

V sedmem poglavju je opisana analiza in validacija razvitega priporočilnega in odločitvenega modela ter praktična uporaba. Glede na podatke o CTR, ki smo jih lahko realno primerjali za določeno oglaševalsko akcijo med našim sistemom in Google Adwords, so ti v prid našemu informacijskemu sistemu, saj je bil splošni CTR skoraj osemkrat večji kot v Google Adwords, in sicer 1,89 % za iskanje, 0,43 % za prikazno omrežje proti 14,2 % v našem priporočilnem sistemu.

V zaključku sem povzel ugotovitve celotne magistrske naloge.

2. Sorodne raziskave

V zadnjih letih se na področju priporočilnih sistemov poskuša najti številne pristope za izboljšanje performanc tradicionalnih priporočilnih tehnik z uporabo hibridnih in povsem novih tehnik, kot so genetski algoritmi, nevronska omrežja in umetno imunska omrežja. Tema magistrske naloge je tesno povezana z raziskavo »Učinki lokacijske personalizacije na posameznikov namen, da uporabi mobilno storitev« (Ying Ho, 2012), kjer avtor ugotavlja, da velika prodornost mobilnega trgovanja spodbuja podjetja, da za prodajo svojih produktov in storitev uporabljajo mobilne tehnologije. Podjetja uporabnikom pošiljajo individualna mobilna sporočila za promocijo produktov in personalizirajo vsebino sporočil, da bi ta bila pomembnejša za posameznega uporabnika. Pomemben faktor pri mobilni personalizaciji je lokacija, saj raziskava preučuje učinek lokacijske personalizacije na posameznikov namen, da uporabi mobilno storitev. Avtor preučuje, kako notranja in zunanja motivacija, ki se oblikuje v začetni fazi, vpliva na posameznikov namen, da storitev uporablja dolgoročno. Raziskava zagotavlja empirične dokaze o učinkovitosti lokacijske personalizacije in pomaga podjetjem razumeti in ovrednotiti nove mobilne priložnosti. Avtor prav tako raziše dejavnike, ki privabijo posameznike k uporabi storitve in jih angažira k dolgoročni uporabi storitve [49].

V raziskavi »Dinamični uporabniški profili za spletno personalizacijo« (Hawalah in Fasli, 2014) sta avtorja ugotovila, da lahko z uporabo spletnih personaliziranih sistemov izboljšamo uporabniško izkušnjo in zagotovimo prirojene storitve glede na uporabniške interese in preference, ki so ponavadi shranjene v uporabniških profilih. Da lahko takšni sistemi ostanejo učinkoviti, se morajo profili ustrezno prilagoditi spremembam uporabnikovega vedenja. Avtorja v študiji predstavita več metod, ki so načrtovane na način, da zajamejo in spremljajo uporabniške interese in vzdržujejo dinamične uporabniške profile. Uporabniški interesi so predstavljeni kot ontološki koncept, ki je zgrajen z mapiranjem obiskov spletnih strani v referenčno ontologijo. Avtorja sta predstavila skupino eksperimentov, ki so pokazali, kako lahko sistem učinkovito modelira dinamične uporabniške profile in se je sposoben naučiti in prilagoditi različnim uporabniškim vedenjem brskanja po spletu [2].

V raziskavi »Skupinsko priporočanje z uporabniško generirano vsebino« (Xu in Yin, 2015) avtorja ugotavljata, da je v obdobju spleta 2.0 (angl. Web 2.0) uporabniško generirana vsebina, kot so komentarji in ocene, prisotna vsepovsod po internetu. Avtorja sta izdelala dva nova statistična modela, ki uporabljata skupinsko filtriranje (angl. collaborative filtering) in modeliranje tem (angl. topic modeling). En model se fokusira na učenje uporabniških preferenc, drugi pa na učenje uporabniških preferenc, vezanih na posamezne produkte. Z učinkovitim napovedovanjem ocen atributom lahko algoritem napove manjkajoče vrednosti posameznih atributov in proizvede interpretabilne teme. Eksperiment je na treh realnih podatkovnih zbirkah pokazal, da lahko predlagani model doseže velike izboljšave glede na nekatere dobro poznane osnovne priporočilne modele [55].

V raziskavi »Razvoj priporočilnega sistema v elektronski napravi uporabnika« (Martinez, Montenegro, Martinez, 2015) so avtorji raziskali možnost uporabe priporočilnega sistema v mobilni napravi, brez močnih strežnikov v ozadju. Ta priporočilni sistem priporoča filme uporabniku glede na njegov profil in pretekle ocene. Glavni cilj je bil razvoj priporočilnega sistema, ki bo priporočal vsebino uporabniku tako online kot lokalno brez internetne povezave. Zaradi številnih omejitev različnih naprav, kot so procesorska moč in spomin, so avtorji morali

prilagoditi kompleksne algoritme za njihovo izvajanje na različnih mobilnih napravah [33].

V raziskavi »Ocenjevanje uporabniškega produktno specifičnega znanja s personalizacijo v elektronskem trgovanju« (Chang, ChangCien, Huang, 2005) avtorji raziskujejo področje uporabniškega znanja o specifičnem produktu. Avtorji predlagajo vključitev domene uporabniškega znanja v proces personalizacije kot del celotne strategije elektronskega poslovanja. Avtorji so predstavili načrt za ocenjevanje uporabniškega znanja o specifičnem produktu z uporabo inovativne metode za neposredno odkrivanje znanja, ne da bi uporabniku postavljali kakršnakoli vprašanja. Metoda analizira navigacijske vzorce skozi spletno vedenje uporabnika. Za primerjavo in učinkovitost metod so avtorji razvili še sistem za ocenjevanje uporabniškega znanja s pomočjo vprašalnikov in ga vgradili v priporočilni sistem. Študija je pokazala, da čeprav je sistem s pomočjo vprašalnika veliko bolj vsiljiv in ga številni uporabniki ne bodo sprejeli, pa predstavlja veliko dodano vrednost za tiste uporabnike, ki so pripravljeni izpolniti vprašalnik. Z združitvijo teh dveh metod v hibridni sistem lahko pridobimo bistveno izboljšano stopnjo natančnosti pri odkrivanju uporabniškega znanja o specifičnem produktu [48].

3. Priporočilni sistemi in sistemi za podporo odločanju

3.1 Priporočilni sistemi

Priporočilne sisteme lahko opredelimo kot programe, ki poskušajo priporočiti najprimernejše produkte in storitve posameznemu uporabniku ali podjetju s pomočjo napovedovanja uporabnikovih želja in interesov za produkt ali storitev. Napovedovanje temelji na povezanih informacijah o uporabnikih, produktih in storitvah ter interakcije med njimi. Namen priporočilnega sistema je zmanjšati informacijsko nasičenje s prioritiziranjem in pridobivanjem najpomembnejših informacij iz velike količine podatkov in na ta način zagotoviti personalizirane produkte, storitve ter informacije. Najpomembnejša lastnost priporočilnih sistemov je njihova sposobnost, da lahko »uganejo« uporabnikove želje, zanimanja in lastnosti z analiziranjem njegovega vedenja ali z analiziranjem vedenja drugih podobnih uporabnikov, in s pomočjo teh informacij ustvarijo osebna priporočila [19].

Priporočilni sistemi so uporabni tako za ponudnika kot uporabnika, saj zmanjšujejo transakcijske stroške iskanja in izbiranja produktov po spletnih straneh, portalih in trgovinah. Priporočilni sistemi prav tako izboljšajo odločitveni proces in kvaliteto odločitev. Na področju e-trgovanja priporočilni sistemi povečujejo prihodke, saj zaradi personalizacije povečujejo prodajo produktov in storitev [11].

Zelo velika ponudba produktov lahko na uporabnika vpliva negativno, saj mu onemogoča, da bi enostavno našel produkt, ki ga želi. Velika ponudba produktov negativno vpliva na enostavnost uporabe in uporabniško izkušnjo v nakupnem procesu. To sta dve zelo pomembni lastnosti spletnih trgovin in portalov, ki vplivata na zadrževanje (angl. retention) uporabnikov. Pri nakupovanju na uporabnika vpliva velika količina različic produktov in produktnih atributov, kar vodi v informacijsko nasičenje in povečuje napor, potreben za sprejem nakupne odločitve. Ta problem v večini primerov vodi v sprejem kompromisa s strani kupca, kar pomeni, da izbere produkt, ki le deloma zadosti njegovim željam in potrebam, kar lahko vodi do zmanjšanja zadovoljstva in prizadene povratek uporabnika [31].

Zaradi pojava dolgega repa (angl. long tail) produktov, to so produkti, ki se prodajajo zelo redko, ampak predstavljajo večino, so priporočilni sistemi potrebni, da lahko uporabniku priporočajo nabor teh produktov. Fizične trgovine imajo omejene prostore na policah in lahko na ta način kupcu predstavijo in ponudijo le majhen izbor vseh možnosti, ki so na voljo. Po drugi strani pa lahko spletne trgovine ponudijo kupcu vse, kar imajo v ponudbi. Fizična trgovina lahko da na polico nekaj tisoč knjig, medtem ko jih ima Amazon v prodaji nekaj milijonov. Fizični časopis lahko natisne le nekaj deset člankov na dan, spletni časopis jih lahko ponudi tudi nekaj tisoč. Priporočanje produktov je v fizičnem svetu veliko lažje, saj v trgovini ni mogoče personalizirati ponudbe vsakemu posameznemu kupcu posebej, prav tako pa je ponudba manjša in izbrana in prodajni rezultati vplivajo na izbiro produktov. To razlikovanje med fizičnim in spletnim svetom je imenovan pojav dolgega repa. Ta sili spletne trgovce, da priporočajo določenemu uporabniku tudi posamezne produkte iz dolgega repa. Ti produkti imajo ponavadi tudi večjo prodajno maržo [23].

Nekateri primeri priporočilnih sistemov so:

1. Priporočila novih člankov v spletnem časopisu, ki temeljijo na napovedi uporabnikovih interesov.
2. Priporočila filmov, ki temeljijo na ocenah ostalih uporabnikov.

3. Priporočila novih produktov v spletni trgovini, ki bi jih kupci želeli kupiti glede na njihovo zgodovino nakupovanja ter zgodovino iskanja in brskanja produktov na spletni strani [23].

3.2 Zgodovina priporočilnih sistemov

Prve raziskave na področju priporočilnih sistemov so se začele iz pridobivanja in filtriranja informacij. Kot samostojno raziskovalno področje so se priporočilni sistemi pojavili šele v sredini 90. let, ko so se raziskovalci začeli osredotočati na težave priporočil, ki temeljijo izključno na podlagi sistema ocenjevanja.

Danes se kot najpogostejše tehnike priporočilnih sistemov uporabljajo skupinsko filtriranje (angl. Collaborative Filtering – CF), vsebinsko filtriranje (angl. Content-based Filtering – CB), filtriranje s pomočjo baze znanja (angl. Knowledge-based Filtering – KB). Vsaka od tehnik ima določene prednosti in slabosti. Skupinsko filtriranje ima težave z redkostjo podatkov (angl. data sparseness), skalabilnostjo (angl. scalability) in hladnim zagonom (angl. cold-start) [19].

CB ima težave s preveč specializiranimi (angl. overspecialized) priporočili, omejeno analizo vsebine in redkostjo podatkov [11]. Za reševanje teh težav so bili predlagani številni napredni pristopi, kot so priporočilni sistemi, ki temeljijo na družbenih omrežjih (angl. social-network), mehki (angl. fuzzy) priporočilni sistemi, kontekstni (angl. context awareness) priporočilni sistemi, hibridni (angl. hybrid) in skupinski (angl. group) priporočilni sistemi [19].

Priporočilni sistemi se danes največ uporabljajo na področju prodaje produktov, filmov, glasbe, televizijskih programov, knjig, dokumentov, spletnih strani, turizma in izobraževanja in vključujejo številna področja od e-trgovine, e-izobraževanja, e-knjžnic, e-uprave in e-storitev [19].

3.3 Priporočilne tehnike

Danes je v uporabi veliko število priporočilnih tehnik, ki so integrirane v različno programsko opremo ali so razvite in v uporabi kot samostojni produkti. Najpogostejše priporočilne tehnike, ki se danes uporabljajo, so: [19]

- skupinsko filtriranje
- vsebinsko filtriranje
- filtriranje s pomočjo baze znanja
- hibridne priporočilne tehnike
- računsko inteligentne priporočilne tehnike
- priporočilne tehnike, temelječe na družbenih omrežjih
- kontekstne priporočilne tehnike
- skupinske priporočilne tehnike

3.3.1. Skupinsko filtriranje

Tehnika skupinskega filtriranja (CF) pomaga uporabnikom sprejeti odločitev na podlagi mnenj ostalih uporabnikov, ki imajo podobne interese in želje. CF se lahko razdeli na uporabniški (angl. user) in predmetni (angl. item) pristop. Pri uporabniškem pristopu bo uporabnik prejel priporočila produktov, ki so vseh

podobnim uporabnikom. Pri predmetnem pristopu bo uporabnik prejel priporočila produktov, ki so podobni tistim, ki so mu bili všeč v preteklosti [19].

CF tehnika deluje na način, da zgradi podatkovno bazo (matriko uporabnik-produkt), interesov, želja in lastnosti za produkte za posameznega uporabnika. Priporočilo, ki je izdelano s strani CF, je lahko napoved ali priporočilo. Napoved je numerične vrednosti [Rij], ki izraža napovedano vrednost produkta j za uporabnika i . Priporočilo pa je lista top N produktov, ki bi jih uporabnik imel najraje prikazane [11].

Metrika podobnosti (angl. Similarity Measure) določa podobnost med dvema uporabnikoma ali podobnost med dvema produktoma. V ta namen primerjamo ocene vseh produktov ocenjenih s strani dveh uporabnikov ali pa ocene vseh uporabnikov, ki so ocenili ta dva produkta [17].

Podobnost med uporabnikom in produktom lahko izračunamo s Pearsonovo korelacijsko podobnostjo (angl. Pearson correlation similarity), omejeno Pearsonovo korelacijsko podobnostjo (angl. constrained Pearson correlation similarity), kosinusno podobnostjo (angl. cosine similarity) ali nastavljivo kosinusno meritvijo (angl. adjusted cosine measures) [19].

Prednost skupinskega filtriranja glede na vsebinsko filtriranje je v tem, da se lahko uporablja tam, kjer ni veliko opisov in vsebin, ki bi bile povezane s produktom, in tam, kjer računalnik zelo težko analizira vsebino. Prav tako ima zmožnost, da daje naključna priporočila, kar pomeni, da lahko priporoča produkte, ki so pomembni za uporabnika, čeprav vsebine in interesov še ni v uporabnikovem profilu [11].

Kljub velikemu uspehu tehnik CF je njihova masovna uporaba pokazala določene pomanjkljivosti:

- Hladni zagon (angl. Cold start) – se nanaša na situacijo, kadar priporočilni sistem nima dovolj ustreznih informacij o uporabniku ali produktu, da bi lahko podal pomembno napoved. To je eden ključnih problemov, ki zmanjšuje učinkovitost priporočilnih sistemov. Profil novega uporabnika ali produkta bo prazen, dokler ta ne bo ocenil nobenega produkta [11]. Ločimo tri tipe problemov hladnega zagona: problem novega uporabnika, novega produkta in nove skupnosti [17].
- Število gruč (angl. Clusters number) – za reševanje težav hladnega zagona se uporablja tehnika grupiranja, vendar ima ta metoda nekatere pomanjkljivosti. Glavno vprašanje, ki se pojavi, je določitev števila gruč v nekaterih metodah grupiranja, saj so performance metode odvisne od preddefiniranega optimalnega števila gruč. Drugi problem je uporabnost identificiranih gruč, saj lahko slabi rezultati grupiranja vodijo do zmanjšanje natančnosti napovedi in stopnje pokritosti priporočila [40].
- Redkost podatkov (angl. Data sparsity) – je problem, ki nastopi kot rezultat pomanjkanja informacij in se zgodi v primeru, ko je uporabnik ocenil le nekaj produktov. To vodi do redke matrike za opis uporabnik-produkt (angl. sparse matrix), nezmožnost poiskati najboljšega soseda in izdelavo slabših priporočil. Redkost podatkov vedno vodi do problema pokritosti, ki kaže odstotek vseh produktov v sistemu, za katere se lahko izdelata priporočila.
- Skalabilnost (angl. Scalability) – je problem, povezan s priporočilnimi algoritmi, saj računske potrebe rastejo linearno s številom uporabnikov in produktov. Težave s skalabilnostjo z namenom, da pospešimo izdelavo priporočil, lahko rešujemo z določenimi tehnikami, kot je npr. zmanjšanje dimenzij. Ena od teh tehnik je razgradnja ene vrednosti (angl. Singular Value

Decomposition SVD), ki omogoča izdelavo zanesljivih in učinkovitih priporočil.

- Sinonimje (angl. Synonymy) – sinonimje je tendenca priporočanja zelo podobnih produktov, ki imajo le malenkost različna imena ali opise. Večina priporočilnih sistemov ima težave z razlikovanjem dveh zelo sorodnih produktov, kot so recimo otroška oblačila ali otroške cunje. Algoritmi CF ponavadi v tem primeru ne najdejo nobenega ujemanja med dvema izrazoma, da bi lahko izračunali njuno podobnost. Za reševanje tega problema se uporabljajo različne metode: avtomatska širitev izrazov (angl. automatic term expansion), gradnja sopomenk (angl. construction of a thesaurus), razgradnja ene vrednosti (SVD) in še posebej latentno semantično indeksiranje (angl. Latent Semantic Indexing). Slabost teh metod je v tem, da imajo lahko nekateri dodani izrazi različen pomen glede na njihov namen, kar lahko včasih vodi do hitre degradacije učinkovitosti priporočilnih sistemov [11].
- Goljufivi napadi (angl. shilling attacks) – ker se priporočilni sistemi veliko uporabljajo v spletnih trgovinah, lahko nepošteni proizvajalci in trgovci povečajo svoj dobiček z goljufanjem priporočilnega sistema, in sicer z uporabo lažnih in zavajajočih podatkov z namenom, da bi se njihovi produkti bolje priporočali. Priporočilni sistem lahko doživi napad, ki bo generiral veliko pozitivnih ocen za določen produkt in bo dodelil negativne ocene za konkurenčni produkt. Priporočilni sistemi so še danes zelo ranljivi na takšne sofisticirane napade [17].

$$s(a, u) = \frac{\sum_{i=1}^n (r_{a,i} - \bar{r}_a)(r_{u,i} - \bar{r}_u)}{\sqrt{\sum_{i=1}^n (r_{a,i} - \bar{r}_a)^2} \sqrt{\sum_{i=1}^n (r_{u,i} - \bar{r}_u)^2}}$$

Enačba 1: Formula za Pearsonovo korelacijo [11]

$$s(\vec{u}, \vec{v}) = \frac{\vec{u} \cdot \vec{v}}{|\vec{u}| * |\vec{v}|} = \frac{\sum_i r_{u,i} r_{v,i}}{\sqrt{\sum_i r_{u,i}^2} \times \sqrt{\sum_i r_{v,i}^2}}$$

Enačba 2: Formula za kosinusno podobnost [11]

2.3.1.1 Zaupanje v priporočilnih sistemih CF

Zaupanje je (angl. trust) v priporočilnih sistemih definirano kot korelacija med podobnimi preferencami za določen produkt, ki so ga ocenili različni uporabniki. Zaupanje izboljšuje priporočilne sisteme z združevanjem podobnosti med uporabniki in način, kako izbiramo soseda, je dopolnjen z vpeljavo zaupanja pri napovedovanju novih povezav med uporabniki. Na ta način lahko povečamo povezljivost med uporabniki in omilimo težave z redkostjo podatkov ter problem hladnega zagona.

V priporočilnih sistemih se uporabljajo številne metrike za merjenje in izračun vrednosti zaupanja med uporabniki in omrežjem. Te metrike so lahko lokalne ali globalne. Lokalne metrike zaupanja uporabljajo subjektivno mnenje aktivnega uporabnika za napoved zanesljivosti ostalih uporabnikov. Vrednost zaupanja predstavlja količino zaupanja, ki jo ima aktivni uporabnik do drugega uporabnika. Po

tej tehniki različni uporabniki različno zaupajo aktivnemu uporabniku in zato je njihova vrednost med seboj različna.

Globalne tehnike zaupanja predstavljajo mnenje celotne skupine do aktivnega uporabnika, zato vsak uporabnik dobi le eno vrednost, ki predstavlja njegovo stopnjo zaupanja v skupnosti. Rezultat zaupanja v globalnih metrikah je izračunan z agregacijo mnenj vseh uporabnikov v skupini glede na aktivnega uporabnika. Primer uporabe globalne tehnike zaupanja je ugled uporabnika (angl. users reputation) v spletni trgovini eBay. Ta izračuna ugled uporabnika glede na število uporabnikov, ki so podali pozitivno, negativno ali nevtralno povratno informacijo za uporabnika ob prodaji produkta. Ko uporabnik še nima definiranega specifičnega mnenja glede drugega uporabnika, se ponavadi zanese na agregirane rezultate zaupanja [11].

2.3.1.2 Tehnike v priporočilnih sistemih CF

Tehnike v priporočilnih sistemih CF lahko razdelimo v dve kategoriji:

- spominske tehnike
- modelske tehnike [11]

Spominske tehnike

Pri spominskih tehnikah igrajo produkti, ki jih je uporabnik ocenil že v preteklosti, pomembno vlogo pri iskanju uporabnikovega soseda, ki deli podobne interese z njim. Ko je sosednji uporabnik izbran, se lahko uporabijo različni algoritmi za izdelavo priporočila. Ta tehnika je zaradi svoje učinkovitosti dosegla široko uporabo v resničnih aplikacijah. Spominska tehnika CF lahko izvaja priporočila s pomočjo podatkov iz ocenjevanja produktov ali uporabnikov [11].

Modelske tehnike

Modelske tehnike upoštevajo ocene iz preteklosti, s pomočjo katerih naučijo in izdelajo model z namenom, da se izboljša učinkovitost tehnike CF. Proces izdelave modela lahko izvedemo s pomočjo strojnega učenja (angl. machine learning) ali rudarjenja podatkov (angl. data mining). Te tehnike lahko zelo hitro priporočijo skupino produktov, saj uporabljajo vnaprej izračunane modele. Prav tako so se izkazale v praksi, saj izdelajo priporočila, ki so podobna tehnikam najbližjega soseda (angl. neighborhood techniques). Z uporabo učnih algoritmov (angl. learning algorithms) se je spremenil tudi način izvedbe priporočil, saj danes ni več samo pomembno, kaj si kdo želi, ampak tudi kdaj si to želi.

V modelskih tehnikah se uporabljajo tudi drugi učni algoritmi:

- Pravilo združenja (angl. Association rule) – algoritem izlušči pravila, ki napovedujejo pojav produkta glede na prisotnost ostalih produktov v transakciji.
- Grupiranje (angl. Clustering) – algoritem poskuša grupirati niz podatkov v več gruč na način, da jih poveže v neke smiselne celote. Ko so gruče oblikovane, se lahko vzame povprečna ocena skupine v gruči in uporabi za priporočilo posameznega uporabnika. Dober algoritem grupiranja mora izdelati visokokvalitetne gruče podatkov, ki bodo imele visoko podobnost znotraj gruče in nizko podobnost med gručami. Algoritmi grupiranja se lahko uporabijo tudi

v algoritmih CB, da zmanjšajo število oseb ali produktov, ki se uporabljajo za izvedbo priporočil [11].

- Odločitvena drevesa (angl. decision tree) – odločitvena drevesa so osnovana na metodologiji drevesnih grafov, ki se zgradijo z analiziranjem primerov za usposabljanje (angl. training examples) in imajo že definirane oznake razredov (angl. class labels). Ta odločitvena drevesa se potem lahko uporabijo za klasifikacijo novih nepoznanih primerov. Če so odločitvena drevesa zgrajena in natrenirana na visokokvalitetnih podatkih, imajo veliko možnosti, da izdelajo zelo natančne napovedi in priporočila.
- Umetna nevronska omrežja (angl. Artificial neural network ANN) – je struktura številnih povezanih nevronov ali vozlišč, ki so na sistematični način nameščeni v plasteh. Povezave med nevroni so utežene in so odvisne od količine vpliva enega nevrone na drugega. Nevronska omrežja imajo nekatere prednosti, saj so zaradi velikega števila povezanih nevronov zelo robustna glede šumov (angl. noisy) in napačnih podatkov. Omrežja ANN imajo sposobnost ocenjevanja nelinearnih funkcij in zajemanja kompleksnih razmerij v podatkih in so lahko učinkovita ter delujejo naprej tudi, če del omrežja izpade. Največja slabost omrežij ANN je v tem, da je težko izdelati idealno topologijo omrežja za določen problem.
- Analiza povezav (angl. Link Analysis) – je proces izdelave omrežij medsebojno povezanih objektov z namenom, da v teh povezavah najdemo ter raziščemo vzorce in trende. Ta algoritem se je izkazal za zelo učinkovitega v izboljšanju spletnega iskanja. Algoritem analize povezav se uporablja tudi v algoritmu PageRank in HITS. Večina algoritmov obravnava spletno stran kot samostojno vozlišče v spletnem grafu.
- Regresija (angl. Regression) – regresijska analiza se uporabi, kadar sta dve ali več spremenljivki sistematično povezani z linearnim razmerjem. Regresija je zelo močan in raznolik proces, ki se uporablja za analiziranje asociativnih (angl. associative) povezav med odvisnimi spremenljivkami in eno ali več neodvisnimi spremenljivkami.
- Bajezijski klasifikator (angl. Bayesian Classifiers) – je verjetnostno ogrodje (angl. probabilistic framework) za reševanje problemov razvrščanja, ki je zasnovano na definiciji pogojne verjetnosti in Bayesovega teorema. Bajezijski klasifikator obravnava vsak atribut in oznako razreda kot naključno spremenljivko. Bajezijski klasifikator se je izkazal za zelo praktičnega v okolju, kjer se podatki o uporabnikovih željah in interesih spreminjajo počasi. Njegova uporaba ni primerna za okolja, kjer se mora model prilagoditi hitro in pogosto.
- Matrična popolnitev (angl. Matrix completion) – bistvo te metode je v napovedovanju in zapolnitvi neznanih vrednosti znotraj matrike uporabnik-produkt. Ena od glavnih tehnik, ki se pojavlja v priporočilnih sistemih CB, je korelacijsko osnovana tehnika K – najbližji sosed (angl. K – nearest neighbor). Ta metoda je zelo odvisna od zgodovinskih podatkov ocenjevanja uporabnika za posamezni produkt. Ta matrika je največkrat zelo velika in redka (angl. sparse), saj uporabniki v večini primerov ne ocenijo vseh produktov, ki so prisotni v matriki. To vodi v nezmožnost sistema, da daje zanesljiva in natančna priporočila uporabniku. Ta metoda je bila predlagana za rešitev Netflixovega problema. Glavna težava te tehnike je v tem, da je proces izdelave modela računsko zelo zahteven in tudi kapaciteta porabe spomina je zelo intenzivna, poleg tega pa metoda ne odpravlja problema hladnega zagona [11].

3.3.2. Vsebinsko filtriranje

Tehnika vsebinskega filtriranja priporoča tiste produkte ali članke, ki so podobni produktu, ki si jih je v preteklosti določil uporabnik želel oziroma si jih je ogledal ali kupil. Osnovni principi priporočilnih sistemov CB so:

- Analiziranje opisov produktov, ki si jih je uporabnik zaželel, ogledal ali kupil ter določitev glavnih skupnih atributov in preferenc (angl. preferences), ki se lahko uporabijo za razlikovanje teh produktov. Te preference se zapišejo v profil uporabnika.
- Izvedba primerjave vseh produktnih preferenc s profilom uporabnika tako, da bodo priporočeni samo produkti z visoko stopnjo podobnosti z uporabniškim profilom.

Pri priporočilnih sistemih CB se uporabljata dve tehniki za ustvarjanje priporočil. Ena tehnika ustvarja priporočila hevristično z uporabo tradicionalnih metod pridobivanja podatkov, kot je kosinusna meritev podobnosti. Druga tehnika ustvarja priporočila z uporabo statističnega in strojnega učenja (angl. machine learning), pretežno z gradnjo modelov, ki so se s pomočjo zgodovinskih podatkov sposobni naučiti o uporabnikovih preferencah in interesih (angl. historical training data) [19]. Priporočilni sistemi CB uporabljajo še nekatere druge tipe modelov za iskanje podobnosti med objekti z namenom, da bi ustvarili še bolj smiselna priporočila. Te metode so: vektorski prostor (angl. vector space model), verjetnostni modeli, kot je naivni Bayesov klasifikator (angl. Naive Bayes Classifier), odločitvena drevesa (angl. Decision Trees) ali nevronska omrežja (angl. Neural Networks) [11].

Priporočilna tehnika CB se najpogosteje uporablja za priporočila spletnih strani, publikacij in novic. Objekti, ki so v večini primerov povezani s pozitivno ocenjenimi objekti, so nato priporočeni uporabniku. Tehnike CB za priporočila ne potrebujejo profilov ostalih uporabnikov, saj podatki o drugih uporabnikih nimajo vpliva na izdelavo priporočila. Tehnika CB ima potencial, da v primeru spremembe uporabniškega profila v zelo kratkem času prilagaja priporočila. Prednost tehnike CB je tudi v tem, da omogoča priporočanje novih produktov, četudi uporabnik ni ocenil nobenega produkta. Tudi če podatkovna baza še ne vsebuje uporabnikovih preferenc, natančnost priporočila ni prizadeta.

Tehnika CB tudi omogoča, da lahko uporabniki dobijo priporočila, ne da bi morali deliti svoj profil, kar zagotavlja in povečuje občutek zasebnosti. Tehnike CB lahko ob priporočilu zagotovijo pojasnilo, kako je bilo priporočilo izdelano za posameznega uporabnika. Slabost priporočilnih tehnik CB je v tem, da morajo pred izdelavo priporočila imeti poglobljeno znanje, odvisne so od produktnih metapodatkov ter zahtevajo bogate opise produktov in dobro organizirane profile uporabnikov. To imenujemo omejena vsebinska analiza (angl. limited content analysis) [11].

3.3.3. Filtriranje s pomočjo baze znanja

Tehnika filtriranja s pomočjo baze znanja priporoča uporabniku produkte na podlagi trenutnega znanja o uporabniku, produktih in medsebojnih povezavah. Priporočilni sistemi KB uporabljajo funkcijsko bazo znanja, ki opisuje, kako določen produkt

izpolnjuje specifične uporabniške potrebe in priporočilo izvede na podlagi sklepanja glede povezave med uporabniško potrebo in priporočenim produktom [19].

Priporočilni sistemi KB so nagnjeni k splošnim pomanjkljivostim vseh sistemov, ki uporabljajo bazo znanja, to je potreba po pridobitvi in izgradnji znanja. Obstajajo tri vrste znanja, ki so udeležene v priporočilnem sistemu KB:

- znanje kataloga (angl. Catalog knowledge) – opisuje znanje o produktih in njihovih lastnostih,
- znanje o uporabniku (angl. User knowledge) – opisuje znanje o uporabnikih in njihovih lastnostih. Za izdelavo dobrih priporočil mora imeti sistem na voljo čim več znanja o uporabniku,
- funkcijsko znanje (angl. Functional knowledge) – opisuje znanje, ki je potrebno, da je sistem sposoben povezati uporabniške potrebe s produkti, ki bodo zadovoljili te potrebe [45].

V priporočilnih sistemih KB se veliko uporablja tehnika obrazložitve na primeru CBR (angl. case based reasoning), kjer priporočilni sistem predstavi objekte kot primere in ustvari priporočila z iskanjem najpodobnejših primerov v preteklosti, glede na uporabnikov profil ali poizvedbo. Obrazložitev na primeru je način reševanja novih problemov na osnovi rešitev iz podobnih primerov v preteklosti [19]. CBR pridobiva izkušnje in rešitve iz preteklosti in jih ponovno uporabi pri ciljanih problemih, kar je podobno naravnemu človeškemu procesu reševanja problemov [5]. Algoritem CBR oceni podobnost med ciljanim primerom (angl. case) in vsemi ostalimi primeri v podatkovni bazi s primerjanjem vrzeli (angl. summarizing feature's gap) med lastnostmi, ki podrobno opisujejo primer. Priporočilni sistem potem izbere primer z najmanjšo vrzeljo kot najprimernejšo rešitev in jo prikaže odločevalcu kot referenčni primer [5].

Za opis problemov pri odločanju lahko v tehniki CBR uporabimo metodologijo hierarhična arhitektura kriterijev (angl. hierarchical criteria architecture HCA), s katero omogočimo odločevalcem, da ustrezno izrazijo svoje probleme [5].

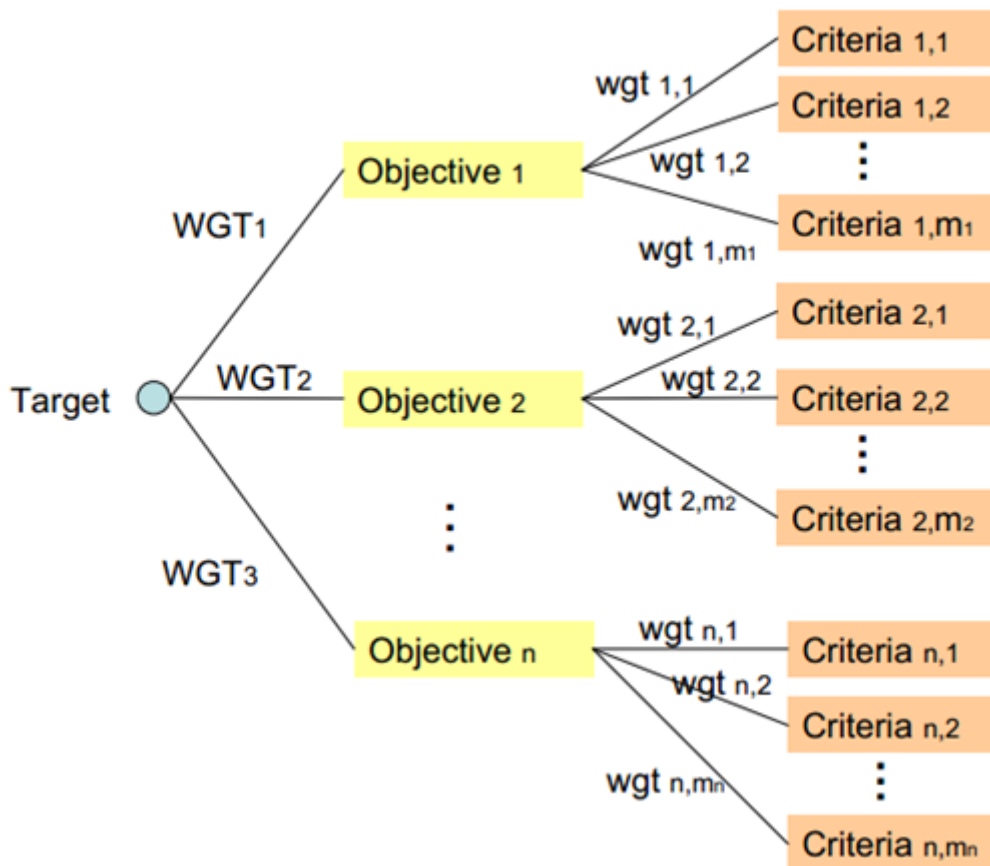
Za predstavitev formalnega znanja se kot metoda uporablja ontologija, ki predstavlja domenski koncept in povezavo med temi koncepti. Semantično podobnost med objekti lahko izračunamo na podlagi domenske ontologije [19].

V večini priporočilnih sistemov CBR se za podatke uporabi produktni katalog, kjer so opisani produkti z vrednostmi atributov. Predlogi produktov za priporočilo so osnovani na meritvi podobnosti med opisi produktov v katalogu in poizvedbo s strani uporabnika ali vzorčnega produkta. Ti priporočilni sistemi imajo veliko skupnega s K-klasifikacijo najbližjega soseda (angl. k-nearest neighbor classification) in top-K poizvedbo (angl. top-k querying). Obe tehniki priporočata seznam k-najpodobnejših produktov za specificirano poizvedbo [19].

Algoritem CBR pred ponovno uporabo pregleda rešitve prejšnjih primerov in obdrži uspešne izkušnje reševanja problemov za ponovno uporabo. CBR ima tako štiristopenjski proces:

- Pridobitev (angl. Retrieve) – glede na definiran problem algoritem iz preteklosti pridobi podobne primere za reševanje tega problema.
- Ponovna uporaba (angl. Reuse) – algoritem poveže in prilagodi rešitev iz preteklega primera z novim problemom.
- Revidiraj (angl. Revise) – novo predlagano rešitev je potrebno stestirati v realnem življenju ali s simulacijo in v primeru nepravilnih rezultatov ponovno revidirati rešitev.

- Ohrani (angl. Retain) – če je izbrana rešitev ustrezno prilagojena izbranemu problemu, shranimo nastalo izkušnjo in rešitev kot nov primer v bazo znanja.



Slika 1: Metodologija HCA za predstavitev problema [5]

3.3.3.1 Priporočanje s predlaganjem ali iskanjem navdiha

V praksi se v nekaterih primerih uporabljajo priporočilni sistemi, ki izdelajo priporočila s predlaganjem ali iskanjem navdiha. Ti priporočilni sistemi ponudijo uporabniku omejeno število vzorčnih produktov, med katerimi lahko uporabnik enega izbere. Potem se na podlagi izbranega produkta pripravi seznam naslednjih priporočenih produktov, med katerimi uporabnik spet izbere enega in tako naprej. Ta pristop podpira idejo, da uporabniki na začetku nimajo vnaprej dobro definiranih preferenc, ampak si preference zgradijo v procesu iskanja.

Nekateri grafični priporočilni sistemi uporabljajo 2D mape, ki imajo tako imenovane inspiracijske vmesnike (angl. inspiration interfaces) in se uporabljajo na področju industrijskega oblikovanja in inženiringa. Ti priporočilni sistemi se uporabljajo za raziskovanje produktov v podatkovni bazi s tako imenovanim interaktivnim načinom [32].

3.3.4. Hibridne priporočilne tehnike

Da bi dosegli večjo učinkovitost in odpravili pomanjkljivosti tradicionalnih priporočilnih tehnik, so se razvile hibridne priporočilne tehnike, ki združujejo najboljše lastnosti dveh ali več priporočilnih tehnik [19].

Hibridne tehnike temeljijo na ideji, da bo kombinacija algoritmov zagotovila natančnejša in učinkovitejša priporočila kot samostojni algoritem. S kombinacijo algoritmov se bo slabost enega algoritma premagala z uporabo drugega algoritma. Kombinacija hibridnih pristopov je lahko različna, od ločene implementacije algoritmov in združevanjem rezultatov, uporabe tehnike CB v skupinskem pristopu CF, uporaba tehnike CF v pristopu CB, izdelava enotnega priporočilnega sistema, ki združuje oba pristopa ... [11].


Pri uporabi hibridnih priporočilnih tehnik se uporablja kombinacija sedmih osnovnih hibridnih mehanizmov:

- utežitev (angl. weighted) – utežena hibridna tehnika združi rezultate različnih priporočilnih sistemov in izdela listo priporočil ali napovedi z uporabo linearne formule.
- mešanje (angl. mixed) – mešane hibridne tehnike združujejo rezultate različnih priporočilnih tehnik in se ne fokusirajo le na eno priporočilno tehniko. Vsak produkt ima tako več priporočil, ki so povezana z različnimi priporočilnimi tehnikami.
- zamenjava (angl. switching) – sistem zamenja eno od priporočilnih tehnik glede na heuristični odraz zmožnosti priporočilnega sistema, da izdela dobro napoved ali priporočilo. Ta hibrid ima možnost, da zaobide problem ene metode, npr. problem novega uporabnika v vsebinskem priporočilnem sistemu, in ga zamenja s skupinskim priporočilnim sistemom. Glavna slabost teh hibridov je predvsem v tem, da ponavadi prinese več kompleksnosti v priporočilni proces, saj je potrebno definirati kriterije zamenjave, kar poveča število potrebnih kriterijev in nastavitev za učinkovita priporočila.
- kombinacija lastnosti (angl. feature combination) – pri tej tehniki lastnosti in preference, izdelane s pomočjo ene priporočilne tehnike, predstavljajo vhod v drugo priporočilno tehniko. Na primer ocene podobnih uporabnikov, ki so lastnost skupinskega filtriranja, se uporabijo v tehnikah CBR z obrazložitvijo na primeru kot ena izmed lastnosti za določitev podobnosti med produkti. Prednost te tehnike je v tem, da se izključno ne zanaša na skupinske podatke. Lastnosti in preference, pridobljene iz različnih priporočilnih sistemov, se v tej tehniki združijo skupaj in so predane naslednjemu priporočilnemu sistemu.
- obogatitev lastnosti (angl. feature augmentation) – ta tehnika uporablja lastnosti, preference ter druge informacije, pridobljene iz predhodnega priporočilnega sistema za izračun novih lastnosti in preferenc, kar predstavlja vhod v naslednji priporočilni sistem. Tehnika z obogatitvijo lastnosti je veliko boljše od tehnike kombinacij lastnosti, saj doda manjše število lastnosti primarnemu priporočilnemu sistemu.
- kaskadiranje (angl. cascade) – ta tehnika uporablja iterativni postopek izpopolnitve pri gradnji vrstnega reda preferenc med različnimi produkti. Priporočilo ene tehnike je izpopolnjeno s priporočilom druge tehnike. Ta hibridna tehnika je zelo učinkovita in tolerantna do šumov (angl. noise) zaradi večkratne iteracije postopka od grobega do finega priporočila.
- meta nivo (angl. meta level) – interni model, izdelan s strani ene priporočilne tehnike, je uporabljen kot vhod v drugo priporočilno tehniko. Na novo

generirani model je vsakič bogatejši z novimi dodatnimi informacijami. Ti modeli lahko rešujejo problem redkosti podatkov tehnike skupinskega filtriranja, kjer lahko celotni model, pridobljen s pomočjo prve tehnike, uporabimo kot vhod v drugo priporočilno tehniko [11].

Najpogostejša praksa na trgu pri obstoječih hibridnih tehnikah je kombinacija tehnike CF z drugimi priporočilnimi tehnikami z namenom, da se izognemo težavam hladnega zagona, redkosti podatkov in skalabilnosti [19].

Hybrid Recommendations



Slika 2: Primer hibridnega priporočilnega sistema

3.3.5. Računsko inteligentne priporočilne tehnike

Računsko inteligentne priporočilne tehnike vključujejo tehnike, kot so: bajezijski (angl. Bayesian) klasifikator, umetne nevronske mreže (angl. artificial neural network - ANN), tehnike grupiranja (angl. clustering techniques), genetski algoritmi (angl. genetic algorithms) in mehke (angl. fuzzy) tehnike.

Bajezijski klasifikator je verjetnostno ogrodje, s katerim rešujemo probleme razvrščanja in je priljubljeno v modelskih (angl. model) priporočilnih sistemih, kjer se pogosto uporablja kot izhodiščni model za priporočilne sisteme CB.

Pri bajezijskih priporočilnih sistemih vsako vozlišče (angl. node) ustreza določenemu objektu in njegovo stanje ustreza vrednosti ocene. V omrežju za vsak objekt obstaja skupina nadrejenih objektov, ki predstavljajo njegove najboljše napovedovalce. Hierarhično bajezijsko omrežje je mogoče uporabiti kot ogrodje za kombiniranje obeh pristopov, CB in CF.

Umetne nevronske mreže so strukture številnih povezanih in uteženih nevronov ali vozlišč, navdih so dobile v arhitekturi bioloških možganov. Uporabijo se lahko za gradnjo modelskih priporočilnih sistemov, prav tako pa se ANN v kombinaciji s CB in CF veliko uporablja za priporočanje filmov in TV-serij.

S tehnikami grupiranja poskušamo združiti objekte v posamezne gruče na način, da so si objekti v določeni gruči podobnejši med seboj kot objekti iz druge gruče. S

tehniko grupiranja lahko občutno zmanjšamo računske operacije za iskanje najbližjih sosedov. Ta tehnika se uporablja v priporočilnih sistemih tudi za reševanje problema hladnega zagona.

Genetski algoritmi predstavljajo stohastične iskalne tehnike, ki so primerne za probleme parametrske optimizacije in zagotavljajo boljšo kvaliteto ter hitrejšo rezultate.

Mehke tehnike ponujajo širok spekter metod za upravljanje nestohastičnih negotovosti. Mehke tehnike se zelo dobro obnesejo pri ravnanju z nenatančnimi informacijami, pri neostri razredov objektov in situacij in postopnem grajenju preferenčnih profilov [19].

3.3.6. Priporočilne tehnike, temelječe na družbenih omrežjih

Za veliko ljudi nakupovanje predstavlja družbeno doživetje in pogosto si pred nakupom želijo slišati še mnenje svojih prijateljev, ljudi s podobnimi interesi ali strokovnjakov s tega področja. Družbeno trgovanje (angl. social commerce) omogoča uporabnikom, da združijo nakupovanje in druženje ter jim nudi možnost, da kupujejo znotraj družbenih omrežij. Na ta način integrira družbena omrežja v spletne trgovine ali dodaja nakupovalne funkcionalnosti v družbena omrežja. Nekatere spletne trgovine že uporabljajo prijateljeve preference, da pomagajo uporabniku izbrati boljšo nakupovalno odločitev. Amazon omogoča, da uporabnik najde knjige in glasbo po avtorjih, ki jih imajo njegovi prijatelji dodane med priljubljene na Facebook profilu [56].

Tehnika analize družbenih omrežij (angl. Social Network Analysis SNA) se uporablja v priporočilnih sistemih kot posledica velikega povečanja uporabe družbenih omrežij v zadnjih letih. Za izboljšanje uporabniške izkušnje priporočilni sistemi omogočajo uporabniku, da se druži in sodeluje (angl. engage) z drugimi podobnimi uporabniki. Te aktivnosti sodelovanja predstavljajo sklepanje prijateljstev, komentiranje, ocenjevanje, všečkanje in znamčenje. Ti novi trendi nudijo priložnost priporočilnim sistemom, da izdelajo priporočila z uporabo uporabnikovih družbenih povezav, še posebej za sisteme, v katerih so podatki preveč skopi za izvedbo skupinskega filtriranja [19].

Nove kontekstualne informacije izboljšujejo delovanje priporočilnih sistemov, saj zmanjšujejo težave, ki nastopijo zaradi redkosti (angl. sparsity) podatkov v spominskih priporočilnih sistemih. Pridobljene informacije iz družbenih omrežij okrepijo in nadgradijo informacije, ki se uporabljajo v priporočilnih sistemih, saj imamo lahko v nekaterih primerih le podatke o uporabniških ocenah. Uporabniki, ki so povezani v družbeno omrežje in si zaupajo, kažejo bistveno večjo podobnost kot nepovezani uporabniki [17].

Večina priporočilnih tehnik, ki temelji na družbenih omrežjih, deluje na principih zaupanja, ugleda in verodostojnosti [17].

»Zaupanje« (angl. Trust) je široko obravnavana tema na področju raziskav družbenih omrežij. V realnem življenju na neko odločitev o nakupu odločilneje vpliva predlog prijatelja kot oglas na spletni strani. Uporabnikovo družbeno omrežje tako lahko predstavlja zelo pomemben vir podatkov v priporočilnem sistemu in predstavlja intuitivno mnenje za ostale uporabnike. V priporočilnih sistemih je beseda »zaupanje« ponavadi definirana kot metrika »kako močno uporabnik A zaupa uporabniku B glede specifičnega produkta«. Dokazano je, da obstaja pozitivna korelacija med zaupanjem in podobnostmi uporabnika (angl. user similarity) v družbenih omrežjih.

Ob zaupanju se v zadnjem času v priporočilnih sistemih uporabljajo še številni drugi tipi družbenih odnosov: družbeni zaznamki in oznake, fizični kontekst, soavtorstvo in ti se uporabljajo kot zamenjava za zaupanje ali podobnost uporabnikov (angl. similarity) pri filtriranju in napovedovanju uporabniških preferenc [19].

Na področju družbenih priporočilnih sistemov lahko uporabniki izdelajo oznake (angl. labels), ki so povezane s produkti. Niz trojice (uporabnik, objekt, oznaka) tvorijo informacijo, poznano kot folksonomija (angl. folksonomies). Folksonomija se lahko uporablja na dva načina: za izdelavo priporočilnih sistemov, ki temeljijo na oznakah, ali za obogatitev priporočilnih sistemov z uporabo oznak [17].

3.3.7. Kontekstne priporočilne tehnike

Pri kontekstnih priporočilnih tehnikah definiramo kontekst kot vsako informacijo, ki se lahko uporabi za opredelitev določene situacije ali entitete. Entiteta je lahko oseba, prostor ali objekt, ki je pomemben za interakcijo med osebo ali aplikacijo, vključno z osebo ali aplikacijo samo. Kontekstne informacije, kot so čas, geolokacijske informacije, zaposlitev v podjetju, prijatelji in družina se zelo pogosto uporabljajo v današnjih priporočilnih sistemih. Še posebej to velja za informacije, ki jih lahko pridobimo preko pametnih telefonov. Kontekstne informacije zagotavljajo pomembne dodatne informacije, ki jih uporabimo pri izdelavi priporočila, še posebej v primerih, kjer ni dovolj, da upoštevamo le uporabnika in objekt, kot je na primer izbira kraja potovanja. Zato je pomembno, da v priporočilne sisteme vključimo kontekste informacije z namenom, da ponudimo uporabniku le tiste produkte, ki so primerni v določenih okoliščinah – na primer turistični priporočilni sistem bo priporočal različne produkte poleti in pozimi [19].

3.3.8. Skupinske priporočilne tehnike

Skupinske priporočilne tehnike (angl. Group recommendation system GRS) se uporabljajo za izdelavo skupinskih napovedi ali priporočil. Uporabimo jih v primeru, ko se uporabniki skupine ne morejo zbrati na enem mestu, da bi se pogajali iz obraza v obraz oziroma njihove preference niso dovolj jasno izražene, kljub temu da so se srečali in zbrali skupaj. Skupinski priporočilni sistemi se uporabljajo na številnih področjih, kot so: film, glasba, spletne strani, dogodki in v kompleksnejših primerih, kot je planiranje izletov in potovanj. Številne strategije, ki so izhajale iz teorije družbene izbire (ang. social choice theory), so uporabljene za agregiranje uporabnikov v skupine. Masthoff je opredelil 11 strategij za združevanje uporabniških modelov:

- Povprečna strategija (angl. Average Strategy) – vzame se povprečje posameznih ocen uporabnikov.
- Strategija najmanjšega zla (angl. Last Misery Strategy) – vzame se najmanjša posamezna ocena. Ta strategija temelji na teoriji, da je skupina tako srečna kot je srečen njihov najmanj srečen uporabnik.
- Najbolj vesela strategija (angl. Most Pleasure Strategy) – vzame se največja posamezna ocena. Ta strategija temelji na teoriji, da je skupina tako srečna kot je srečen njihov najbolj srečen uporabnik.
- Povprečna strategija brez zla (angl. Average Without Misery Strategy) – vzame se povprečje posameznih ocen, vendar vzamemo le ocene, ki so nad določenim pragom; recimo vse ocene produktov, ki imajo oceno vsaj 2.

- Poštena strategija (angl. Fairness Strategy) – pri teh strategiji so izbrani najboljši produkti izmed vseh posameznikov. Če ima več produktov enako oceno, se upoštevajo druga merila.
- Strategija najbolj spoštovane osebe (angl. Most Respected Person Strategy) – uporabi se ocena najbolj spoštovane osebe. Ta strategija temelji na teoriji, da lahko ena oseba dominira v skupini [22].
- Skupinsko glasovanje (angl. Plurality Voting) – pri tej strategiji vsak volivec voli svojo najljubšo alternativo. Alternativa z največ glasovi zmaga.
- Utilitaristična strategija (angl. Utilitarian Strategy) – pri tej strategiji se ob uporabi vrednosti posameznih ocen za vsako alternativo uporabijo tudi utilitaristične vrednosti, ki izražajo pričakovano srečo.
- Borda Count (Borda, 1781) – pri tej strategiji vsaki alternativni dodelimo točke, ki so odvisne od pozicije alternative v posameznikovi preferenčni listi.
- Copelandovo pravilo (Copeland, 1951) (angl. Copeland Rule) – pri tej strategiji se uporablja oblika skupinskega glasovanja. Za sortiranje alternativ se uporablja Copelandov indeks, ki izraža število, kolikokrat je alternativa premagala drugo alternativo, zmanjšano za število, kolikokrat je alternativa izgubila proti drugi alternativni.
- Odobritev glasovanja (angl. Approval Voting) – pri tej strategiji lahko ocenjevalci glasujejo za neomejeno število alternativ. Ta strategija se uporablja za spodbujanje izvolitev zmernih alternativ, to so alternative, ki niso zelo nepriljubljene [21].

Pri skupinskih priporočilnih sistemih je pomembno, kako uporabniki komunicirajo med seboj. Za kontekstualne vsebine, glasbo in filme je zelo uporabljana asinhrona komunikacija. Za izbiro TV-programov so primerna off-line pogajanja, za turistična priporočila pa je najbolj primerna sinhrona komunikacija, če skupina želi zagotoviti kvalitetno izbiro potovanja [19].

3.4 Uporaba priporočilnih sistemov

Priporočilne sisteme se uporablja na številnih področjih:

- e-uprava
 - personalizacija javnih storitev
 - pomoč volivcem pri odločanju na volitvah
 - personalizirani zdravstveni nasveti in storitve
 - pomoč gospodarstvu pri izbiri poslovnih partnerjev
- e-poslovanje
 - priporočila glede produktov in storitev
 - priporočila pri spletnih avkcijah
 - priporočila pri pogajalskih procesih
 - priporočila pri investicijskem portfelju
- e-trgovanje
 - priporočila na podlagi ocen produktov in storitev
 - priporočila na podlagi označevanja (angl. tagging) produktov in storitev
 - priporočila na podlagi preteklih in predvidevanja prihodnjih nakupov
 - priporočila pri promocijskih ponudbah
- e-knjžnice
 - priporočila za izbiro virov znanja in informacij

- priporočila za izbiro virov raziskav
- personalizirane e-knjižnične storitve
- e-izobraževanje
 - priporočila študentom za izbiro predmetov in učnih materialov
 - priporočila učiteljem za izbiro pedagoških metod in vzorcev
 - priporočila v spletnih izobraževalnih sistemih s personalizirano podporo
- e-turizem
 - priporočila za turiste in izbiro potovanja, znamenitosti, namestitve
 - priporočila za izbiro hotelov, restavracij, bencinskih postaj
 - priporočila za muzeje in kulturno dediščino
- e-viri
 - priporočila za glasbo, video, filme, novice in dokumente
 - priporočila za spletne strani, e-pošto
 - priporočila za dodajanje oznak (angl. tag) [19]

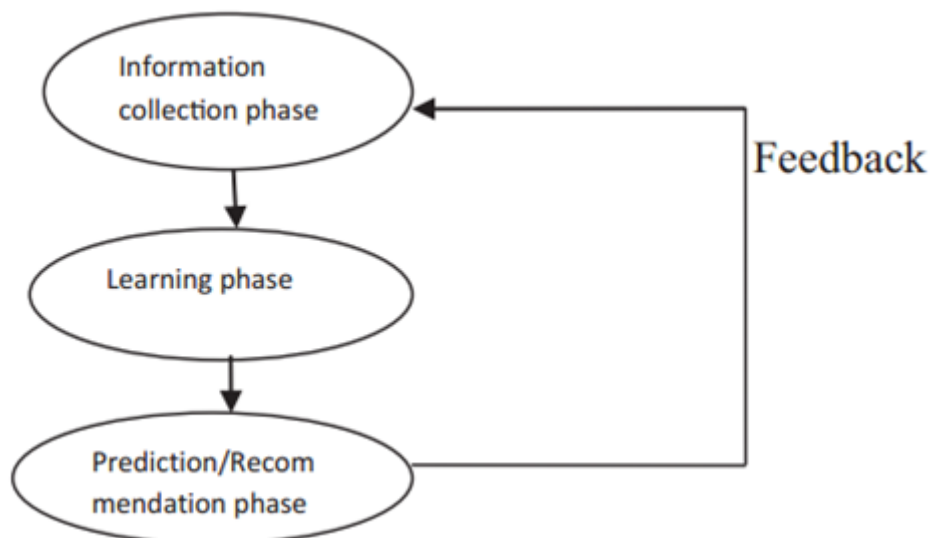
Če danes pogledamo uporabo priporočilnih sistemov, ugotovimo:

- V večini primerov se še vedno uporabljajo klasični priporočilni pristopi (CF, CB, KB), vendar največkrat kot kombinacija hibridnih priporočilnih tehnik, in sicer zaradi izogibanja pomanjkljivostim posameznih priporočilnih tehnik.
- Najpogosteje se uporabljajo priporočilni sistemi na področju e-virov in v večini primerov so uporabljeni za priporočanje posameznemu uporabniku.
- Na področju e-izobraževanja so najpogosteje uporabljene tehnike filtriranja s pomočjo baze znanja, medtem ko so na področju e-virov najpogosteje uporabljene tehnike CF.
- V zadnjem času se vedno pogosteje uporabljajo nove priporočilne tehnike, kot so kontekstni priporočilni sistemi in priporočilni sistemi, ki temeljijo na družbenih omrežjih.
- Za obvladovanje različnih negotovosti se vedno pogosteje uporabljajo računsko inteligentne priporočilne tehnike, kot je recimo mehka logika (angl. fuzzy logic)
- Ob priporočilnih sistemih na spletu se pojavljajo nove platforme in kanali, kot so mobilne aplikacije, pametni TV in radio [19].

3.5 Faze priporočilnega procesa

Priporočilni proces ima tri faze:

- zbiranje informacij,
- faza učenja,
- faza napovedovanja in priporočanja.



Slika 3: Faze priporočilnega procesa [11]

3.5.1. Zbiranje informacij

V prvi fazi zberemo pomembne informacije o uporabnikih in izdelamo uporabniške profile ali modele za izvedbo priporočil ali napovedovanja. Ti podatki vključujejo uporabniške želje, preference, vedenje in vsebine, do katerih je uporabnik dostopal. Priporočilni sistem ne more delovati natančno, dokler niso zgrajeni kvalitetni uporabniški profili ali modeli.

Priporočilni sistemi temeljijo na različnih tipih pridobljenih informacij. Najbolj priročna je visokokvalitetna eksplicitna povratna informacija, ki vključuje eksplicitni vnos uporabnikovih interesov in želja glede posameznega produkta ali storitve. Pridobljene informacije lahko pridobimo tudi z implicitnimi povratnimi informacijami, kjer razberemo uporabnikove želje in potrebe posredno preko opazovanja vedenja uporabnika. Uspeh kateregakoli priporočilnega sistema temelji večinoma na zmožnostih, da kvalitetno predstaviti uporabnikove trenutne interese. Pri eksplicitni povratni informaciji sistem čez uporabniški vmesnik pozove uporabnika, da vnese oceno za produkt z namenom, da zgradi in izboljša svoj model. Natančnost tega modela je zelo odvisna od števila pridobljenih ocen s strani uporabnikov.

Pri implicitni povratni informaciji sistem avtomatsko sklepa o uporabnikovih interesih in željah preko spremljanja različnih preteklih akcij, kot so: zgodovina nakupov, zgodovina brskanja in navigacije, porabljen čas na spletni strani, sledenje povezavam, vsebina e-pošte, kliki na gumbе itd. Implicitna povratna informacija zmanjša breme uporabnika pri vnosu podatkov in sklepa, kaj si uporabnik želi ali potrebuje preko spremljanja vedenja. Implicitna metoda je manj natančna, zato je za pridobitev najboljših rezultatov smiselno združiti obe povratni informaciji, saj s tem zmanjšamo slabosti in dobimo boljše podatke za priporočilni sistem [11].

Priporočilni sistem lahko zbira demografske podatke o uporabniku (starost, nacionalnost, spol), družbene informacije, kot so (sledilci, komu uporabnik sledi, tvite, objave, komentarje, ocene) in informacije od interneta stvari (angl. Internet of Things), kot so (GPS-lokacija, RFID, zdravstveni podatki). Priporočilni sistem tako

za svoje delovanje in za zagotavljanje napovedi in priporočil uporablja različne vire informacij [17].

3.5.2. Faza učenja

V tej fazi se razvije algoritem za učenje, ki filtrira in izkoristi uporabnikove potrebe in želje, ki smo jih pridobili preko zbiranja informacij.

3.5.3. Faza napovedovanja in priporočanja

V tej fazi priporočilni sistem napove ali priporoča, katere produkte ima uporabnik najraje in si jih trenutno želi. Faza napovedovanja in priporočanja se lahko izvede direktno na podatkih, ki smo jih zbrali v fazi pridobivanja podatkov in temelji na spominskih tehnikah (angl. memory based) ali uporabi modelske tehnike (angl. model based) [11].

Za proces izdelave priporočila je tako potrebno predvideti in upoštevati:

1. Podatke, zbrane v podatkovni bazi (ocene, lastnosti, družbene povezave ...)
2. Izbrani algoritem filtriranja (CB, CF, KB ...)
3. Izbrani model (spominske tehnike direktno na podatkih ali modelske tehnike)
4. Uporaba izbranih tehnik (verjetnostni pristop, bayesovo omrežje ...)
5. Določitev ravni redkosti podatkovne baze in zelene skalabilnosti
6. Performančnost sistema (poraba časa in spomina)
7. Zelena kvaliteta rezultatov (pokritost, natančnost ...) [17]

3.6 Metrike vrednotenja priporočilnih sistemov

Kvaliteto priporočilnih algoritmov lahko ocenimo z uporabo različnih tipov meritev, kot so recimo natančnost, pokritost in raznolikost. Vrsta metrike je odvisna od tipa priporočilne tehnike. Natančnost meri delež pravilnih priporočil glede na vsa možna priporočila. Pokritost meri delež objektov v polju iskanja, kjer sistem lahko izvede priporočilo.

Metrike za merjenje natančnosti priporočilnih sistemov so razdeljene na statistične in metrike, ki merijo natančnost pri podpori odločanju. Primernost obeh metrik je odvisna od lastnosti priporočilnega sistema ter podatkov in tipa nalog, ki jih priporočilni sistem mora izvesti.

Metrike statistične natančnosti (angl. Statistical accuracy metrics) ovrednotijo natančnost tehnike filtriranja s primerjavo napovedane ocene z aktualno oceno uporabnika. Tri najpogostejše uporabljene metrike so: srednja absolutna napaka (angl. Mean Absolute Error MAE), zgornja srednja kvadratna napaka (angl. Root Mean Square Error RMSE) in korelacija. MAE je najpriljubljenejša in najpogostejša uporabljena metrika in meri deviacijo priporočila glede na uporabnikovo specifično oceno. V formuli za izračun MAE je $P_{u,i}$ je napovedana vrednost za uporabnika u za produkt i . $R_{u,i}$ pa je dejanska aktualna ocena. Manjši kot je MAE, natančneje priporočilni sistem napove uporabniške ocene.

$$\text{MAE} = \frac{1}{N} \sum_{u,i} |p_{u,i} - r_{u,i}|$$

Enačba 3: Formula za izračun srednje absolutne napake MAE

RMSE daje več poudarka absolutni napaki in manjši kot je, boljša je natančnost priporočilnega sistema.

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{u,i} (p_{u,i} - r_{u,i})^2}$$

Enačba 4: Formula za izračun zgornje srednje kvadratne napake RMSE

Metrike za merjenje natančnosti podpora odločanju, ki so priljubljene in pogosto uporabljene, so: stopnja preobrata (angl. Reversal rate), obtežena napaka (angl. Weighted errors), operativne značilnosti sprejemnika (angl. Receiver Operating Characteristics ROC), krivulja odpoklica točnosti (angl. Precision Recall Curve PRC), točnost (angl. Precision), odpoklic (angl. Recal) in F-meritev (angl. F-measure).

$$\text{Precision} = \frac{\text{Correctly recommended items}}{\text{Total recommended items}}$$

$$\text{Recall} = \frac{\text{Correctly recommended items}}{\text{Total useful recommended items}}$$

Enačba 5: Formula za izračun točnosti in odpoklica

F-meritev nam pomaga poenostaviti meritve točnosti in odpoklica v enotno metriko. Izračunana vrednost omogoča lažjo in enostavnejšo primerjavo med algoritmi in podatki.

$$F\text{-measure} = \frac{2PR}{P + R}$$

Enačba 6: Formula za izračun F-meritve

Metrika pokritosti nam pove, kakšen je procent produktov in uporabnikov, za katere lahko priporočilni sistem izdela napoved ali priporočilo. Napoved je praktično nemogoče izvesti, če je produkt ocenilo zelo malo uporabnikov ali celo nobeden. Pokritost lahko zmanjšamo, če definiramo manjše velikosti sosesčin (angl. neighborhood sizes) za uporabnika ali produkt [11].

Metriki za raznolikost, ki se največ uporabljata, sta novost (angl. novelty) in raznolikost (angl. diversity). Ocena novosti prikaže stopnjo razlike (angl. degree of difference) med priporočenim in tistim produktom, ki je uporabniku že poznan. Raznolikost se uporablja za merjenje stopnje raznolikosti (angl. degree of differentiation) med priporočenimi produkti [17].

V zadnjem času se je fokus iz natančnosti priporočilnih sistemov (angl. accuracy) razširil še na druga področja, kot sta novost in raznolikost. To je nastalo predvsem iz potrebe, da se najde pot za priporočanje produktov iz dolgega repa (angl. long-tail), ki so kupcu nepoznani, ampak so zanj še zmeraj pomembni. Če priporočamo produkte iz dolgega repa, lahko porazdelimo prodajo produktov, ki je ponavadi koncentrirana okoli nekaj zelo poznanih in ocenjenih produktov do manj znanih nišnih produktov z višjo maržo [27].

Priporočilni sistemi, ki so fokusirani na raznolikost, uporabljajo različne metode, kot so: maksimiranje mrežnega pretoka (angl. Network flow maximization), selektivna predvidljivost (angl. selective predictability), entropija (angl. Entropy) in mrežno skupinsko filtriranje (angl. Network-based collaborative filtering) [27].

3.7 Kvaliteta priporočilnih sistemov

Kvaliteta priporočil ima lahko velik učinek na uporabnikovo nadaljnje vedenje pri nakupovanju. Slaba priporočila lahko povzročijo dve vrsti značilnih napak:

- Lažni negativni (angl. False negatives) – to so produkti, ki niso priporočeni, čeprav bi si jih kupec želel.
- Lažni pozitivni (angl. false positives) – to so produkti, ki so priporočeni, čeprav jih kupec ne želi.

Na področju e-trgovanja se je najpomembneje izogniti lažni pozitivni, saj to vodi v jezo in frustracijo uporabnikov, ki lahko privede do tega, da bo uporabnik zapustil spletno trgovino [53].

3.8 Trendi priporočilnih sistemov

Od začetka evolucije priporočilnih sistemov in do danes vidimo vedno večjo težnjo po zbiranju in integraciji vedno večjega tipa in količine podatkov. Ta trend se paralelno razvija z razvojem spleta, ki ga lahko razdelimo na tri glavna obdobja:

1. Ob nastanku spleta so priporočilni sistemi uporabljali le eksplicitne ocene, pridobljene s strani uporabnikov, njihove demografske podatke ter vsebinske informacije, vključene s strani lastnika priporočilnega sistema.
2. Ob razvoju spleta 2.0. so priporočilni sistemi skupaj z ostalimi informacijami začeli zbirati in uporabljati podatke, pridobljene preko družbenih omrežij (prijatelji, sledilci, kdo komu sledi). Ob tem se pogosto zbirajo še uporabniško generirane vsebine, kot so blogi, oznake, komentarji, video, slike.
3. Ob prihodu spleta 3.0 so začeli zbirati in uporabljati podatke od interneta stvari, to so kontekstne informacije iz različnih tipov naprav in senzorjev. Trenutno najpogosteje uporabljena informacija je geografska in lokacijska informacija. Se pa kažejo trendi zbiranja podatkov na področju telemetrije, podatkov RFID, nadzornih podatkov, zdravstvenih podatkov, prehranjevalne in nakupovalne navade ter virtualne resničnosti.

Kontekstni priporočilni sistemi se fokusirajo na dodatne kontekstne informacije, kot so čas, lokacija, podatki iz senzorjev. Trenutno se zaradi narave mobilnih naprav zelo povečuje uporaba geografskih informacij, ki jih lahko imenujemo tudi lokacijsko zavedajoče (angl. location-aware).

Obstaja jasen trend zbiranja implicitnih informacij namesto tradicionalnih eksplicitnih vrednotenj produktov preko ocenjevanja uporabnika. Vključitev implicitnih informacij o dnevni navadah uporabnikov omogoča priporočilnemu sistemu uporabo različnih podatkov. Zaradi narave teh podatkov je zelo pomembno izpostaviti zasebnost in varnost podatkov, ki se lahko uporabljajo le s soglasjem uporabnikov.

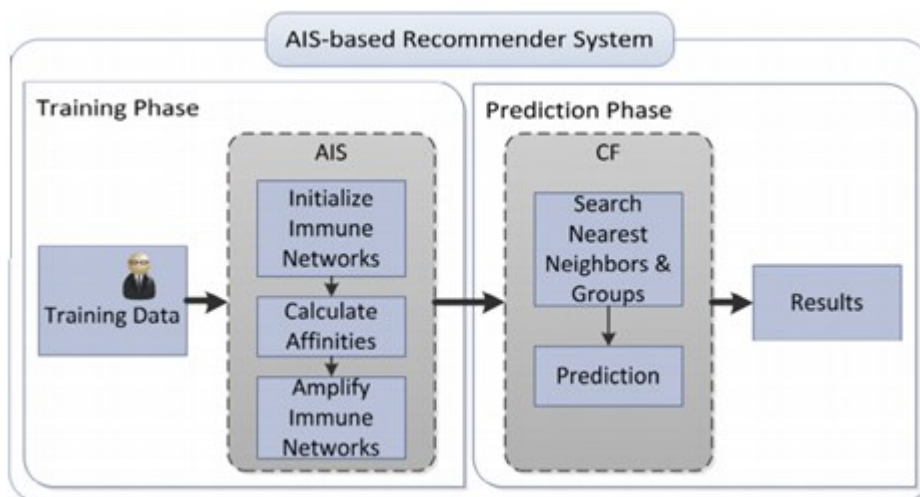
Na področju priporočilnih sistemov se pojavljajo trendi bio navdihljenih (angl. Bio-inspired) pristopov, ki primarno uporabljajo genetske algoritme (angl. Genetic Algorithms GA), nevronska omrežja (angl. Neural Networks NN) in umetno imunska omrežja (angl. Artificial Immune Networks). Genetski algoritmi uporabljajo hevristične pristope na podlagi evlucijskih principov, kot sta naravna selekcija in preživetje najmočnejšega. Model nevronske omrežje je osnovan na podlagi opazovanja vedenja bioloških nevronov. Ta model poskuša simulirati način, kako možgani procesirajo informacije, kar omogoča računalnikom, da se »učijo« do neke določene stopnje. Nevronske omrežje se tipično sestoji iz večjega števila medsebojno povezanih vozlišč. Vsako vozlišče obravnava določeno sfero znanja in ima več vhodov iz omrežja. Glede na vhodne podatke, ki jih pridobi, se vozlišče lahko »nauči« o povezavah in odnosih med podatki ter vzorcih.

Umetno imunski sistemi (AIS) so porazdeljeni in prilagojeni sistemi, ki uporabljajo modele in načela iz človeškega imunskega sistema. Modelirajo obrambni sistem, ki lahko ubrani naše telo pred infekcijami [17]. Ker algoritmi uporabljajo prilagodljive imunske odzive, se uporabljajo predvsem za iskanje rešitev problemov optimizacije. Tukaj gre za zelo kompleksne sisteme, ki so sposobni obdelave in procesiranja velike količine informacij in izvedbe nalog, kot je izbira funkcij (angl. feature selection), prepoznavanje vzorcev (angl. pattern recognition), učenje (angl. learning) in odpoklic spomina (angl. memory recall). Obstajajo trije glavni imunološki principi, ki so uporabljeni v imunskih priporočilnih sistemih: teorija imunskega omrežja (angl. immune network theory), negativna selekcija (angl. negative selection) in klonska selekcija (angl. clonal selection) [34].

Običajno je proces izdelave modela imunskega sistema sestavljen iz faze treninga in faze testiranja. V fazi treniranja vsak zapis z oceno uporabnika obravnavamo kot antigen in podobnost je definirana kot afiniteta v AIS. Ko antigeni napadejo imunski sistem, se izdelajo protitelesa in nastane imunske omrežje, ki je zgrajeno iz prvih k-protiteles. Ko je začetno imunske omrežje zgrajeno, izračunamo afiniteto vsakega trening podatka in imunskega omrežja. Če je afiniteta višja od določenega praga, bo antigen razširil imunske omrežje oziroma ustvaril novo imunske omrežje. Na koncu faze treninga tako pridobimo več imunskih omrežij, kjer se protitelesa združijo v skupni boj z antigeni.

Pri razvoju imunskega omrežja najprej naključno izberemo nekaj antigenov. V naslednji fazi izbiramo antigene z najnižjo afiniteto do obstoječega imunskega omrežja, in sicer z namenom, da izdelamo še druge začetne mreže, dokler se ne doseže predpisano število omrežij. To preprečuje, da bi bila izdelana omrežja zgrajena s podobnimi antigeni, ki lahko vodijo do neuspeha pri treningu zaradi nezadostne imunske sposobnosti [34].

Ko je imunsko omrežje zgrajeno, ga uporabimo za napoved ocene uporabnika za določen produkt. Ker je imunsko omrežje natrenirano z vsemi antigeni, vemo, v katero omrežje vsak antigen (uporabnik) spada. Faza napovedi najprej najde skupino najbližjih sosedov za aktivnega uporabnika in glede na imunsko omrežje potem napove uporabnikovo oceno.



Slika 4: Priporočeno ogrodje za umetno imunski priporočilni sistem

3.9 Proces rudarjenja podatkov

Pri odločanju je vsak poslovni problem, ki temelji na podatkih, unikaten in vsebuje svojo kombinacijo ciljev, želja, omejitev in celo osebnostnih preferenc odločevalca. V sodelovanju s poslovnimi nosilci podatkovni znanstveniki razdelijo poslovni problem na več ločenih podnalog. Rešitve posameznih nalog lahko potem združimo v rešitev celotnega problema.

Kljub velikemu številu specifičnih algoritmov za rudarjenje podatkov ti algoritmi pokrivajo le peščico različnih nalog:

- **Klasifikacija in ocena verjetnosti razreda** (angl. Classification and class probability estimation) – klasifikacija poskuša za vsakega posameznika v populaciji napovedati, v katere razrede ta posameznik spada. Pogosto se ti razredi medsebojno izključujejo. Primer klasifikacijskega vprašanja bi bil »Za katere naše stranke obstaja največja verjetnost, da se bodo odzvale na našo ponudbo?« Za rešitev tega primera lahko naredimo dva razreda »Se bo odzval« in »Se ne bo odzval« in nato v procesu rudarjenja podatkov izdelamo model, ki bo za vsakega novega uporabnika določil razred, v katerega spada. Tesno povezana naloga s klasifikacijo je točkovanje (angl. scoring) oziroma ocena verjetnosti razreda, ki za vsakega uporabnika namesto napovedi razreda izdelava oceno, ki predstavlja verjetnost, da posameznik spada v posamezni razred. V našem primeru bi lahko za vsakega posameznika izračunali oceno verjetnosti, da se bo odzval na ponudbo.
- **Regresija ali ocena vrednosti** (angl. value estimation) – regresija poskuša za vsakega posameznika napovedati ali oceniti numerično vrednost za posamezne spremenljivke. Primer regresijskega vprašanja bi bil »Kako pogosto bo uporabnik uporabljal našo storitev?« Spremenljivka, ki jo napovedujemo ali

ocenjujemo, je pogostost uporabe storitve, zato v procesu rudarjenja podatkov izdelamo model na podlagi podobnih uporabnikov in z uporabo njihovih zgodovinskih podatkov napovemo oceno. Regresija je povezana s klasifikacijo, vendar med njima obstaja razlika, saj klasifikacija napoveduje, ali se bo nekaj zgodilo, medtem ko regresija napoveduje, kako pogosto se bo zgodilo.

- Podobnost ujemanja (angl. Similarity matching) – algoritem poskuša identificirati podobne uporabnike glede na podatke, ki jih imamo zbrane o uporabnikih. Podobnost ujemanja je osnova za eno najpriljubljenejših metod za priporočanje produktov, kjer poiščemo skupino uporabnikov, ki so podobni meni glede na to, katere produkte so kupili ali jih imajo radi.
- Grupiranje (angl. Clustering) – algoritem poskuša grupirati uporabnike ali produkte glede na njihovo podobnost. Primer vprašanja za grupiranje bi bilo »Ali naše stranke oblikujejo naravne skupine ali segmente?«
Grupiranje se uporablja v predhodnih fazah raziskovanja, da vidimo, katere naravne skupine obstajajo; zanje lahko potem uporabimo druge tehnike rudarjenja podatkov. Rezultati grupiranja se pogosto uporabljajo kot vhod v druge priporočilne tehnike, ki se fokusirajo na vprašanja »Katere produkte bi ponudili kupcem?« ali »Kako naj bo strukturirana naša prodajna ekipa za posamezne skupine kupcev?«
- Skupinsko pojavljanje (angl. Co-occurrence grouping) – v praksi poznano tudi kot rudarjenje pogostih postavk, odkrivanje pravil povezav ali analiza košarice produktov. Algoritem v tem primeru poskuša poiskati povezave med entitetami glede na skupne transakcije. Primer vprašanja bi bil »Kateri produkti so pogosto kupljeni skupaj?«. Če grupiranje išče podobnosti med produkti in uporabniki glede na njihove skupne attribute, skupinsko pojavljanje ugotavlja podobnost med objekti glede na njihovo skupno pojavljanje v transakcijah.
- Profiliranje (angl. Profiling) – v praksi poznano kot opis vedenja, kjer algoritem poskuša opredeliti tipično vedenje posameznika, skupine ali celotne populacije. Primer profiliranega vprašanja bi bil »Kakšna je tipična uporaba telefonskih storitev za ta segment kupcev?« Vedenje ponavadi nima enostavnega opisa, ampak lahko vsebuje kompleksne opise različnih stanj. Profiliranje se pogosto uporablja za vzpostavitev vedenjskih norm in za detekcijo anomalij, kot je na primer preprečevanje zlorab in nadziranje vdorov v informacijske sisteme. Če je za uporabnika znano, kje in kako nakupuje in kaj počne s kreditno kartico, lahko enostavno določimo, ali novo plačilo s kreditno kartico ustreza temu profilu ali ne. Uporabimo lahko tudi stopnjo neuskklajenosti za izračun ocene suma zlorabe in sprožimo alarm, če je ocena prevelika.
- Napovedovanje povezav (angl. Link prediction) – algoritem poskuša napovedati povezavo med objekti s predlaganjem povezave, ki naj bi v prihodnosti obstajala in oceni moč te povezave. Napovedovanje povezav se pogosto uporablja v družbenih omrežjih, saj če na primer dva uporabnika delita deset skupnih prijateljev, potem bo zelo verjetno, da bi lahko bila prijatelja tudi sama. Napovedovanje povezav tvori osnovo za družbene priporočilne sisteme.
- Zmanjšanje podatkov (angl. Data reduction) – algoritem poskuša vzeti velik nabor podatkov in ga zamenjati z manjšim naborom, ki vsebuje kar se da največ pomembnih podatkov iz celotnega nabora. Z manjšim naborom podatkov lahko enostavneje upravljamo in jih lažje procesiramo. Zmanjšanje podatkov ponavadi vključuje izgubo informacij, zato je potrebna previdnost.

- Vzročno modeliranje (angl. Causal modeling) – algoritem poskuša razumeti, kateri dogodki ali akcije dejansko vplivajo na druge dogodke. Tehnike za vzorčno modeliranje vključujejo tehnike, ki zahtevajo znatne naložbe v podatke, kot so na primer naključni kontrolirani preizkusi, tako imenovani A/B testi, kot tudi zelo sofisticirane metode za prikaz vzorčnih sklepov iz opazovanih podatkov. Pri vzorčnem modeliranju mora menedžment pretehtati kompromis med povečanjem investicij za zmanjšanje domnevanja in med odločitvijo, da so sklepi zadovoljivo dobri ne glede na domneve. Odkritje placebo efekta v medicini ponazarja razvpito stanje, kjer so domneve spregledali v skrbno načrtovanem naključnem eksperimentu [12].

Proces rudarjenja podatkov vključuje veliko znanosti, tehnologije in tudi umetnosti. Ker je to že uveljavljena obrt, obstajajo dobro definirani procesi, ki na problem postavijo strukturo in ogrodje ter omogočajo razumno skladnost, ponovljivost in objektivnost. Proces rudarjenja podatkov zahteva stalne ponovitve podprocesov (angl. iteration), kar je to v praksi prej pravilo kot izjema. Pogosto je celoten proces raziskovanja podatkov dolgotrajen in po prvi iteraciji podatkovni znanstveniki vedo o problemu veliko več kot prej, zato je lahko naslednja iteracija veliko bolj informirana in podrobna. Proces rudarjenja podatkov je po CRISP (angl. Cross Industry Standard Process for Data Mining) metodi sestavljen iz šestih iterativnih procesov:

- Razumevanje poslovanja in problemov (angl. Business Understanding) – v tej prvi fazi mora projektna skupina podrobno razmisliti o problemu, ki ga je potrebno rešiti in o scenariju uporabe rešitve. To je eno izmed najpomembnejših osnovnih načel znanosti o podatkih.
- Razumevanje podatkov (angl. Data Understanding) – če je ključni cilj rudarjenja podatkov reševanje poslovnih problemov, potem so podatki tisti razpoložljivi surovi material, iz katerih bomo zgradili rešitev. Pomembno je, da razumemo prednosti in omejitve podatkov, saj se v praksi zelo redko zgodi, da imamo popolno ujemanje s problemom. Zgodovinski podatki so pogosto zbrani za namene, ki so nepovezani s poslovnim problemom ali so bili zbrani brez kakšnega posebnega namena. Baza strank, transakcijska baza in marketinška baza lahko vsebujejo različne informacije in pokrivajo različne segmente populacije, zato imajo lahko različne stopnje zanesljivosti.
- Priprava podatkov (angl. Data Preparation) – analitične tehnologije, ki jih uporabljamo za rudarjenje podatkov, so močne, vendar imajo določene zahteve glede podatkov, ki jih uporabljajo. Pogosto se zgodi, da so podatki v različni obliki, kot pa so bili sprva narejeni, zato je potrebna pretvorba. Tipičen primer priprave podatkov je pretvorba podatkov v tabelarno strukturo, odstranjevanje ali sklepanje manjkajočih vrednosti in pretvorba podatkov v različne formate. Numerične vrednosti je pogosto potrebno normalizirati tako, da jih lahko nato primerjamo med seboj.
- Modeliranje (angl. Modeling) – faza modeliranja je proces, kjer nastane neke vrste model ali vzorec, ki zajame povezave v podatkih. Splošno povedano je model poenostavljena predstavitev realnosti.
- Vrednotenje (angl. Evaluation) – namen faze vrednotenja je stroga ocena rezultatov rudarjenja podatkov in pridobitev zaupanja, da so rezultati pravilni in zanesljivi, preden lahko gremo v naslednjo fazo. Če zelo natančno analiziramo podatke, bomo našli raznorazne vzorce, vendar ni nujno, da bodo ti podatki preživeli skrbni pregled. Pri vrednotenju želimo vzpostaviti zaupanje, da so

modeli in vzorci, izvlečeni iz podatkov, pravi in regularni ter da vmes ni anomalij. Prav tako je pomembno, da faza vrednotenja zagotavlja, da model ustreza originalnim poslovnim ciljem in problemom. Vrednotenje rezultatov rudarjenja podatkov vključuje tako kvantitativne kot kvalitativne ocene.

- Uvedba (angl. Deployment) – pri uvedbi so rezultati rudarjenja podatkov in njihovih tehnik dani v realno uporabo z namenom, da rešujejo poslovne probleme in da povrnejo investicijo. Največkrat sama uvedba pomeni implementacijo prediktivnega modela v določenem informacijskem sistemu ali poslovnem procesu. Se pa povečuje uvedba samostojnih tehnik rudarjenja podatkov, na primer v spletnem oglaševanju, kjer so uvedeni sistemi, ki avtomatsko zgradijo in stestirajo model v produkciji, kadar se pojavi nova oglaševalska kampanja [12].

3.10 Gradnja uporabniškega modela

Ključna prednost personaliziranih priporočilnih sistemov je njihova zmožnost, da se naučijo in prepoznajo uporabniške preference. Da lahko personalizirani priporočilni sistem izdela ustrezna priporočila, zahteva ustrezne uporabniške modele, ki predstavljajo njegove interese, želje in potrebe. Informacije o uporabniških interesih lahko dobimo na več načinov. V praksi se pogosto uporablja modeliranje uporabniških interesov skozi tekstovno rudarjenje (angl. text mining). Proces tekstovnega rudarjenja poteka v treh fazah:

- Izvlečenje izrazov (angl. extracting terms) – v tej fazi najprej odstranimo nezaželene besede (angl. stop words) in sopomenke (angl. stemming words). Nato iz celotnega teksta izvlečemo izraze in jih predstavimo kot vektor posameznih izrazov.
- Rudarjenje pogostih vzorcev (angl. mining frequent patterns) – v tej fazi z rudarjenjem podatkov poiščemo pogoste vzorce izrazov za posameznega uporabnika. Ker ima vsak uporabnik različne interese, mora biti vsebina za tekstovno rudarjenje izbrana za vsakega uporabnika posebej. Pogosti vzorci predstavljajo niz izrazov, ki pogosto nastopajo skupaj v uporabnikovih interesnih vsebinah.
- Obrezovanje vzorcev (angl. pruning patterns) – v tej fazi iz niza pogostih vzorcev odstranimo vzorce, ki vsebujejo nepotrebne izraze. Na koncu definiramo še pomembnost vsake besede v določenem vzorcu, ki jo imenujemo utežni vzorec (angl. pattern weight) [15].

Spletne podatke o vedenju uporabnika lahko pridobimo v različnih formatih in oblikah. Ti podatki so lahko obiskani URL-naslovi, vsebina spletne strani ter vhodne in izhodne povezave na spletno stran. Glede na analizirane podatke lahko spletno rudarjenje razdelimo na tri področja:

- rudarjenje spletnega brskanja,
- rudarjenje spletne vsebine,
- rudarjenje strukture spletnih strani preko spletnih povezav [43].

V zadnjih letih se zanimanje za uporabo tehnik rudarjenja spletnih vsebin v priporočilnih sistemih povečuje. Slabost teh tehnik pa je, da se ne obnesejo najbolje pri nenehnih spremembah spletnih vsebin, kot je recimo pri spletnih časopisih ali dinamično kreiranih spletnih straneh. To povzroča velike težave, saj moramo zelo

pogosto posodabljati model. Zato je za takšne spletne strani boljše uporabiti tehniko rudarjenja uporabe spletnega brskanja.

3.10.1. Rudarjenje uporabe spletnega brskanja

Rudarjenje uporabe spletnega brskanja (angl. web usage mining) se osredotoča na napovedovanje uporabniških preferenc in vedenja z analiziranjem datotek spletnih dnevnikov (angl. web logs). Uporabniški podatki o klikanju po spletnih straneh (angl. clickstream) so lahko zelo bogat vir podatkov o uporabniku. Klikanje označuje uporabnikovo pot skozi spletno stran in ti podatki so shranjeni v datoteki spletnega dnevnika. Večino podatkov za rudarjenje najdemo na strežnikih, proxy strežnikih, podjetniških dnevnikih (angl. enterprise logs) in odjemalčevih dnevnikih (angl. web clients logs). Celoten proces rudarjenja podatkov je razdeljen na tri dele: pridobivanje in priprava podatkov, odkrivanje vzorcev in analiza vzorcev.

V večini primerov so spletni podatki po sami naravi dvoumni in jih je potrebno pred nadaljnjo analizo očistiti. Raziskave kažejo, da je skoraj 80 % časa pri rudarjenju porabljenega za predprocesiranje podatkov. V dnevnikih so shranjeni navigacijski podatki, ki vključujejo vse obiskane spletne strani in shranjujejo naslednje podatke: IP-naslov, čas, čas branja, kodo statusa, URL, metodi GET ali POST, uporabniški posrednik (ang. User agent) in napotitveni URL (angl. Referrer URL).

V fazi predprocesiranja najprej ločimo odvečne attribute, nato filtriramo osamele podatke, poiščemo URL pripone in odstranimo zapise s pripomami, kot so .gif, .jpg, .tif. V naslednji fazi se odstranijo vsi zapisi s statusom napake, ki imajo status s kodo napake od 200 do 299. Nato za vsak IP-naslov dodelimo unikati uporabniški ID, da lahko uporabnike ločimo med seboj. Za vsak uporabniški ID zgradimo sejo (angl. session) in v fazi grupiranja seje (angl. session clustering) združimo seje, ki pripadajo istemu uporabniku. Seja nam tako predstavlja celoten niz aktivnosti, ki so bile izvedene s strani uporabnika v določenem času. Na koncu še vse podatke formatiramo in jih shranimo v podatkovno bazo v obliki tabele [41].

Med navigacijske vzorce uvrščamo brskanje, iskanje, klik na produkt, dodajanje v košarico in nakup produkta. Iz teh podatkov lahko potem dobimo vedenjske vzorce, kot so: čas ogleda in branja spletne strani, število obiskov posameznega produkta, število klikov in razmerje, informacije o tiskanju, zaznamki (angl. Bookmarking) za določene produkte. Iz teh podatkov lahko sklepamo, da produkt, ki je pogosto obiskan in ogledan, spada med priljubljene produkte. Iz vzorcev lahko sklepamo, da je kategorija produktov, ki ima zelo veliko razmerje klikov (angl. click ratio), uporabniku verjetno všeč in da ima to kategorijo produktov raje kot katero drugo [52].

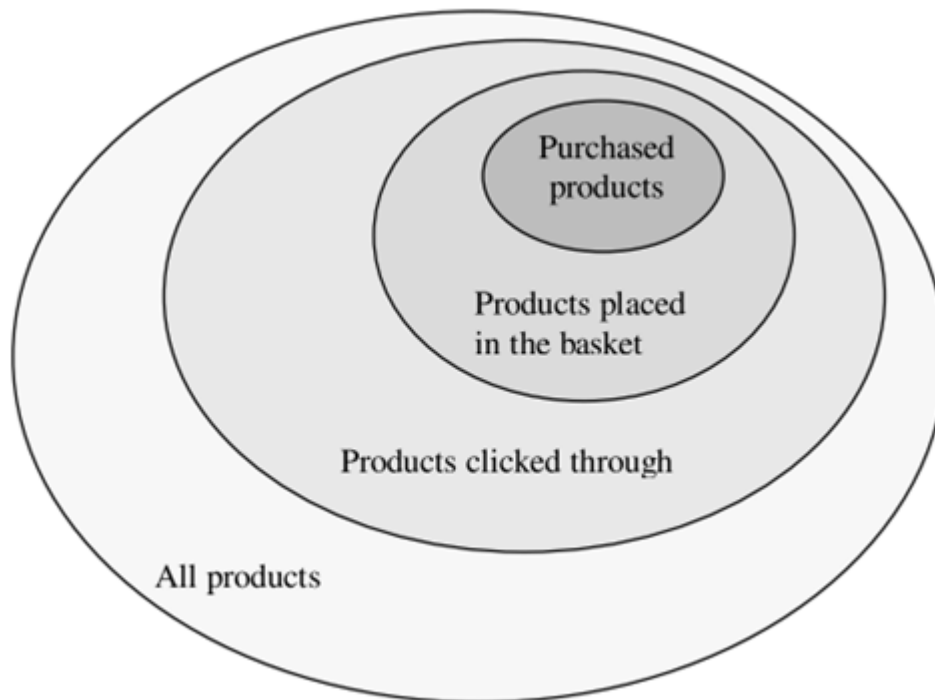
Faza odkrivanja vzorcev (angl. pattern discovery) vključuje naloge, kot so: odkrivanje pridružitvenih pravil (angl. association rules discovery), sekvenčnih vzorcev (angl. sequential patterns), gruče uporabe (angl. usage clusters), gruče spletnih strani (angl. page clusters) ali uporabniške klasifikacije (angl. user classifications). Vzorce, pridobljene iz spletnih podatkov, lahko uporabimo za spletno personalizacijo, izboljšanje sistema, spremembe spletnih strani, poslovne analitike ali prikaz uporabniškega potovanja [53].

Uporabniški model preferenc je v spletnih trgovinah v večini primerov zgrajen iz treh splošnih nakupovalnih korakov:

- klikanje (angl. click-through) – kliki na povezave in ogled spletne strani produkta,

- dodajanje v košarico (angl. basket placement) – dodajanje izdelka v nakupovalno košarico,
- nakup (angl. purchase) – nakup produkta in zaključek transakcije.

Smiselno je, da določimo višje uteži kupljenim produktom kot tistim, ki so bili dodani v košarico. Podobno moramo dati višje uteži produktom, ki so bili dodani v košarico kot tistim, ki so bili samo ogledani, in tako naprej [53].



Slika 5: Klasifikacija produktov glede na nakupno vedenje uporabnika [53]

3.10.2. Rudarjenje nakupnih podatkov preko terminala POS

V fizičnih trgovinah lahko podatke o uporabniških preferencah in vedenju pridobimo preko velikega števila transakcijskih podatkov preko terminala POS. Ti podatki se lahko uporabljajo za preučitev uporabnikovega nakupnega procesa, še posebej na področju marketinga. Čeprav je uporaba takšnih podatkov zelo pogosta v spletnih trgovinah, se danes pri prodaji iz obraza do obraza (angl. face to face) v fizičnih trgovinah to še zmeraj uporablja bolj poredko, razen v večjih trgovskih podjetjih. Podatki POS odražajo nakupno vedenje uporabnika, in sicer kdo je kupil, kateri produkt je kupil, kdaj je kupil, koliko je kupil in koliko je plačal.

Največja težava pri rudarjenju nakupnih podatkov je redkost (angl. sparsity) podatkov, saj je število različnih produktov, ki jih uporabnik dejansko kupi, zelo majhno glede na skupno število vseh produktov. To lahko vodi do slabih priporočil [37].

3.11 Sistemi za podporo odločanju

Odločanje je proces, v katerem moramo med več možnostmi in variantami izbrati takšno varianto, ki najbolj ustreza postavljenim ciljem oziroma zahtevam. Odločanje je v našem življenju prisotno vsak dan, pa naj gre za zasebno ali poslovno odločanje. Odločanje je tako del splošnega reševanja problemov in se dogaja kot miselna aktivnost na vseh področjih delovanja.

Težavnost odločitvenih problemov je raznolika. Segajo od enostavnih osebnih odločitev, ki so večinoma rutinske in se jih večinoma niti ne zavedamo, vse do težkih problemov skupinskega odločanja. Najpomembnejši izzivi, ki nastopajo pri težkih odločitvenih problemih, izvirajo iz (Bohanec in Rajkovič, 1995):

- velikega števila dejavnikov, ki vplivajo na odločitev,
- številnih oziroma slabo definiranih ali poznanih variant,
- zahtevnega in pogosto nepopolnega poznavanja odločitvenega problema in ciljev odločitve,
- obstoja več skupin odločevalcev z nasprotujočimi si cilji,
- omejenega časa in drugih virov za izvedbo odločitvenega procesa.

Sistemi za podporo odločanju (angl. Decision support systems) so informacijski sistemi, ki se fokusirajo na podporo in izboljšanje vodstvenega odločanja. V bistvu pri DSS govorimo o razvoju in uvajanju IT-sistemov za podporo procesom odločanja. DSS je bilo zelo pomembno področje raziskovanja informacijskih sistemov že od začetka 70. let, saj ima lahko pomemben vpliv na naravo in uspešnost organizacije. DSS ni homogeno področje in ima več kot 45-letno zgodovino in veliko število različnih področij. Glavna področja DSS so:

- Osebnih sistemov za podporo odločanju (angl. Personal Decision Support Systems) so ponavadi manjši sistemi, ki so razviti za enega menedžerja ali manjšo skupino neodvisnih menedžerjev za podporo odločanju.
- Skupinski sistemi za podporo odločanju (angl. Group Support Systems) uporabljajo kombinacijo komunikacijskih in DSS-tehnologij, ki omogočajo učinkovito delovanje skupin.
- Pogajalski sistemi za podporo odločanju (angl. Negotiation Support Systems) so DSS-sistemi, kjer je primarni fokus skupinskega dela pogajanje med nasprotnima strankama.
- Inteligentni sistemi za podporo odločanju (angl. Intelligent Decision Support Systems) uporabljajo tehnike umetne inteligence za podporo odločanju.
- Sistemi za podporo odločanju z upravljanjem znanja (angl. Knowledge Management Based DSS) omogočajo odločanje s shranjevanjem, pridobivanjem, prenosom in uporabo znanja, ki omogoča individualni in organizacijski dostop do znanja.
- Podatkovna skladišča (angl. Data Warehousing) so sistemi, ki zagotavljajo veliko in obsežno podatkovno infrastrukturo za podporo odločanju.
- Sistemi za poročanje in analizo (angl. Enterprise Reporting and Analysis Systems) so sistemi, ki se fokusirajo na večja podjetja in vključujejo informacijske sisteme za vodilne kadre, poslovno analitiko ter sisteme za upravljanje uspešnosti. Orodja za poslovno analitiko dostopajo in analizirajo podatke v podatkovnih skladiščih z uporabo predefinirane programske opreme za poročanje in uporabo orodij za proizvodbe in analize [9].

Sistemi za podporo odločanju pomagajo uporabnikom sprejemati odločitve pri reševanju polstrukturiranih ali nestrukturiranih problemov, kjer naletijo na nepopolne in negotove informacije. Sistemi za podporo odločanju imajo cilj odločevalcem zagotoviti najboljše znanje z namenom, da sprejmejo boljše, informirane, preglednejše in učinkovitejše odločitve [1].

Moderni sistemi za podporo odločanju danes uporabniku zagotavljajo širok nabor funkcionalnosti in zmogljivosti. Današnji DSS-sistemi nam olajšajo delo pri najrazličnejših nalogah odločanja, kot so zbiranje in analiza informacij, izgradnja modelov, analiza občutljivosti, sodelovanje, alternativno vrednotenje in implementacija odločitev. Pogosto so DSS-sistemi zgrajeni za ad hoc analize, vendar se povečuje število integracij sistemov za podporo odločanju v poslovne procese in ostale informacijske sisteme. V zadnjih letih ti sistemi dobivajo preporod pri uporabi odločitvenih tehnologij v svetovnem spletu in mobilnih aplikacijah. Spletni in mobilni DSS nudi podporo pri odločanju vodstvenim kadrom ali poslovnim analitikom preko lahkega odjemalca (angl. thin client), to je spletnega brskalnika ali mobilne aplikacije [13]. Spletni DSS je zmanjšal tehnološke ovire, olajšal delo in zmanjšal stroške za izdelavo DSS-sistemov. Prav tako je dostopen vodstvenim kadrom in ostalim zaposlenim na geografsko različnih lokacijah [18].

Sistemi za podporo odločanju so ponavadi sestavljeni iz:

- sofisticirane podatkovne baze, ki ima dostop do internih in eksternih podatkov, informacij in znanja,
- močnih funkcij za modeliranje, do katerih ima dostop sistem za upravljanje modelov,
- enostavnega uporabniškega vmesnika, ki omogoča izdelavo interaktivnih poizvedb, poročil in drugih grafičnih funkcij.

V večjih podjetjih se je sprejemanje odločitev preselilo iz osebnih odločitev do sprejemanja odločitev v manjših skupinah, kjer skupina različnih posameznikov sprejema kompleksne in pomembne odločitve. Pri tem skupinskem odločanju se uporabljajo različna orodja za podporo sodelovanju in komunikaciji ter orodja za načrtovanje in izvajanje procesov. Ker imajo posamezniki, ki sodelujejo v skupini, le delne skupne cilje in imajo lahko določene parcialne interese, moramo koordinirati in organizirati aktivnosti posameznikov na način, da zagotovimo, da vsi sledijo istemu skupnemu cilju. Skupinska odločitev se doseže preko medosebne komunikacije znotraj skupine v računalniško podprtem okolju. Skupine lahko komunicirajo sinhrono ali asinhrono, lahko so locirane skupaj ali delujejo na daljavo [18].

Sisteme za podporo odločanju lahko razdelimo v več tipov:

- Komunikacijski DSS (angl. Communication-driven) – ti sistemi se večinoma uporabljajo za interne skupine za potrebe komunikacije in lahko pomagajo pri vodenju sestanka ali pri sodelovanju in organiziranju dela med uporabniki. Primeri komunikacijskih DSS so recimo spletne klepetalnice. Večina njihovih funkcionalnosti izhaja iz komunikacijskih in informacijskih tehnologij, ki se uporabljajo v sistemih za podporo skupnemu odločanju.
- Podatkovni DSS (angl. Data-driven DSS) – ti sistemi se večinoma uporabljajo pri vodstvenih kadrih in direktorjih. Z uporabo poizvedb v podatkovnih skladiščih poiščemo odgovore na specifična vprašanja.

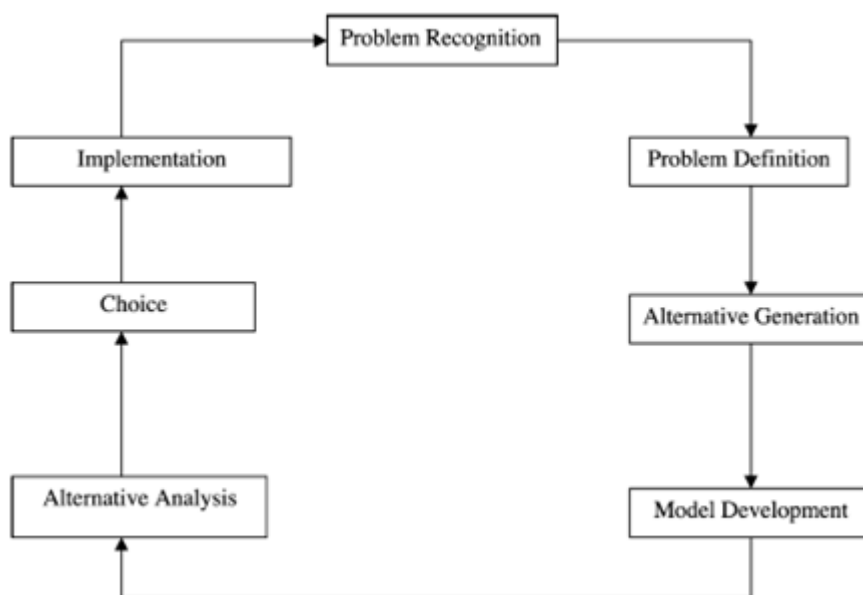
- Dokumentni DSS (angl. Document-driven DSS) – ti sistemi so pogostejši in so namenjeni široki množici uporabnikov. Namen takih DSS je analiziranje spletnih strani ter iskanje dokumentov za določen nabor ključnih besed in iskalnih nizov.
- DSS na podlagi baze znanja (angl. Knowledge-driven DSS) – ti sistemi se večinoma uporabljajo za svetovanje vodstvenim delavcem ter pri izboru produktov in storitev.
- Modelni DSS (angl. Model-driven DSS) – to so zelo kompleksni sistemi, ki pomagajo pri analizah ali pri izbiranju med različnimi možnostmi.

3.11.1. Modelni DSS

Modelni DSS je oblikovan na način, da ima uporabnik možnost manipulirati s parametri modela z namenom, da preuči občutljivost izhodov ali da izvede ad hoc »Kaj če« (angl. what if) analizo. Ena glavnih komponent modelnih DSS so kvantitativni modeli in najpogosteje se uporabljajo: algebrske in diferencialne enačbe (angl. algebraic and differential equation models), analitični hierarhični proces (angl. analytical hierarchy process), odločitvena matrika (angl. decision matrix), odločitvena drevesa (angl. decision tree), večatributni (angl. multi-attribute) in večkriterijski model (angl. multi-criteria models), napovedni modeli (angl. forecasting models), omrežni in optimizacijski modeli, Monte Carlo, diskretne simulacije dogodkov in kvantitativno vedenjski modeli (angl. quantitative behavioral models).

Modelni DSS uporabljajo podatke in parametre, ki jih je zagotovil odločevalec, in pomagajo pri analiziranju okoliščin, vendar ti sistemi niso podatkovno zelo intenzivni. Črpanje, preoblikovanje in nalaganje podatkov je del izgradnje DSS in občasno tudi modelnega DSS. Pri nekaterih modelnih DSS uporabnik vnese vse podatke, ki jih sistem potrebuje, in DSS izvede validacijo in hrambo podatkov [8].

Odločitveni proces v DSS daje poudarek razvoju modelov in analizi problema. Ko je problem prepoznan, se ga opredeli v pogojih, ki olajšajo izdelavo modela. Nato se ustvari alternativne rešitve in razvije modele, ki analizirajo različne alternative. Na koncu odločitvenega procesa se izbere najboljšo rešitev in se jo implementira. V večini primerov odločitveni procesi ne potekajo po tako jasno določenih postopkih, ampak se faze med seboj prekrivajo in mešajo, s pogostim vračanjem v prejšnje faze, ko je o problemu vedno več znanega ali ko rešitve padejo.



Slika 6: Prikaz procesa odločanja v sistemih za podporo odločanju

3.12 Poslovna analitika

Poslovna analitika (ang. Business intelligence and analytics) je podatkovno usmerjen DSS, ki vključuje zbiranje in shranjevanje podatkov ter upravljanje znanja z namenom, da priskrbi podatke za proces odločanja. Poslovna analitika obdeluje in analizira veliko število podatkov o podjetju in njegovih poslovnih procesih..

V informacijskem okolju poslovna analitika uporablja veliko podatkovno bazo, ponavadi shranjeno kot podatkovno skladišče ali datamart, kar predstavlja osnovo za sofisticirane analize. Analize obsegajo vse od enostavnih poročil, drill-down poročil, izvajanje ad-hoc poročil, rudarjenja podatkov, analiz v realnem času do planiranja.

Danes poslovna analitika vključuje tudi orodja za merjenje poslovne učinkovitosti (ang. business performance measurement – BPM) in orodja za spremljanje poslovne aktivnosti (ang. business activity monitoring – BAM). Dogaja se ekspanzija uporabe poslovne analitike od posameznih uporabnikov do uporabe skozi celotno organizacijo, kar pomeni, da se poslovna analitika vključuje v poslovne procese podjetja.

3.13 Strojno učenje

Že od začetka digitalne dobe so znanstveniki razmišljali o možnostih, da bi računalniki reagirali na spremembe v podatkih brez dodatnega programiranja, podobno kot se ljudje učijo iz sprememb v svojem okolju. Če bi lahko računalnik spremenil svoje programske modele, ko se spremenijo vhodni podatki, bi se lahko uporabil kot orodje za pomoč pri sprejemanju odločitev o prihodnosti. Zmožnost, da lahko računalniki zagotovijo natančno napoved na podlagi prejetih informacij, imenujemo strojno učenje (angl. machine learning). Strojno učenje se danes uporablja v številnih internetnih produktih in storitvah, ki jih uporabniki uporabljajo vseskozi – od zaznavanja nezaželene pošte, demografskega grupiranja do

priporočanja produktov in storitev. Strojno učenje je zelo kompleksno področje različnih algoritmov, zato obstaja velika verjetnost napačne uporabe različnih tehnik in algoritmov za določen problem. Zato je zelo pomembno, da je izbrani algoritem strojnega učenja izvedljiv za specifični podatkovni izziv. Če pogledamo primere algoritmov grupiranja (angl. clustering), imamo zelo veliko različnih modelov za grupiranje podobnih podatkovnih točk. K-means algoritem postavlja podatkovno točko diskretno v posebno skupino, kjer pa podobni algoritem Fuzzy K-means lahko postavi točko v več kot eno skupino. Izbira enega ali drugega algoritma je odvisna od tega, kako dobro obravnava problem, ki ga rešujemo. Veliko pozornosti strokovnjakov je pritegnilo strojno učenje na področju priporočilnih sistemov, saj se njihovi algoritmi zdijo najbolj humani. V vsakdanjem življenju smo zelo odvisni od našega družbenega in družinskega kroga in se z njimi posvetujemo glede nakupovanja, dopustovanja in drugih odločitev.

Za reševanje zahtevnih in velikih podatkovnih problemov potrebujemo skalabilno infrastrukturo za strojno učenje. Hadoop MapReduce in Spark so algoritemski pristopi, s katerim razbijemo velike podatkovne probleme, torej tiste, ki jih ni enostavno reševati z enim računalnikom, v manjše probleme, ki so lahko porazdeljeni čez večje število ločenih računalnikov. V letu 2006 je skupina računalniških znanstvenikov iz Stanforda objavila članek imenovan »MapReduce for Machine Learning on Multicore«, kjer opisujejo, kako se lahko MapReduce algoritem uporabi za reševanje različnih problemov, kot so grupiranje, Bayesov klasifikator in regresija. Apache Mahout je odprtokodna skupina knjižnic, ki lahko pomaga povečati število izvedenih nalog strojnega učenja čez več gruč strežnikov (angl. clusters of machines) z uporabo porazdeljenega ogrodja, kot je Apache Hadoop [35].

3.14 Apache Hadoop

V letu 2002 sta avtorja Doug Cutting in Mike Cafarella ob razvoju spletnega iskalnika »Nutch«, ki je bil specializiran za brskanje, indeksiranje in iskanje spletnih strani, obupno iskala rešitev za procesiranje velike količine informacij. Leto dni pozneje je Google objavil študijo Google File System (GFS) in MapReduce algoritem, ki predstavljata distribuirano programsko platformo za procesiranje velikih podatkovnih zbirk. Avtorja Cutting in Cafarella sta prepoznala prednosti pristopa s strani Googla za distribuirano procesiranje ter hrambo skozi gručo strežnikov. Googlovo študijo sta vzela kot osnovo za razvoj distribuirane platforme za Nutch, kar je kasneje prineslo do razvoja HDFS – Hadoop Distributed File System in Hadoopove implementacije algoritma MapReduce. Leta 2006 je Yahoo, ki je prav tako imel velike težave z indeksiranjem velikega obsega informacij za svoj iskalnik, najel Douga Cuttinga in hitro posvojil Hadoop kot ogrodje za reševanje izzivov iskalnika. Yahoo je potem predal Hadoop kot odprtokodno rešitev v Apache projekt in v zadnjih 10. letih se je Hadoop razvil v najpriljubljenejšo splošno namensko računalniško platformo za reševanje Big Data izzivov. Podjetje IDC je napovedalo, da bo Hadoop poganjal večino Big Data trga in bo dosegel 23 milijard \$ prihodkov v 2016.

Apache Hadoop se sooča z izzivi Big Data in velikimi količinami podatkov s poenostavitvijo implementacije podatkovno intenzivnih in visoko paralelnih distribuiranih aplikacij. Hadoop se uporablja v poslovnem svetu, na univerzah in drugih organizacijah ter omogoča, da lahko analitične naloge razdelimo na manjše koščke (angl. fragment) in jih porazdelimo na več tisoč strežnikov. To paralelno

procesiranje zagotavlja hitre analitične čase in porazdeljeno hrambo velikanske količine podatkov. Hadoop zagotavlja stroškovno učinkovit način za hrambo enormnih količin podatkov in zagotavlja skalabilen in zanesljiv mehanizem za procesiranje velikih količin podatkov preko gruče navadnih cenejših strežnikov. Nudi tudi nove in izboljšanje analitične tehnike, ki omogočajo sofisticirano analitično procesiranje multistrukturnih podatkov. Za večino uporabnikov Hadoopa je najpomembnejša lastnost ločitev med poslovnim programiranjem in infrastrukturo, saj Hadoop zakrije kompleksnost infrastrukture in nudi enostavno platformo za izvedbo kompleksnih distribuiranih računskih operacij za zahtevne probleme.

Hadoop se od prejšnjih distribuiranih pristopov razlikuje na naslednje načine:

- podatki so porazdeljeni že vnaprej,
- podatki so podvojeni (angl. replicated) čez gručo strežnikov z namenom zanesljivosti in razpoložljivosti,
- procesiranje podatkov se poskuša izvesti tam, kjer so podatki shranjeni, kar odpravlja ozka grla pri pasovnih širinah ob prenosu podatkov.

Hadoop prav tako zagotavlja močno ogrodje za podatkovno analizo in nudi:

- Velike količine prostora za shranjevanje – Hadoop omogoča aplikacijam, da delujejo znotraj več tisoč računalnikov in petabyte podatkov. Tisoče manjših cenejših računalnikov lahko povežemo v gruče, s katerimi dobimo skupno računalniško moč, ki lahko znatno preseže posamezne superračunalnike za veliko nižjo ceno.
- Distribuirano procesiranje s hitrim dostopom do podatkov – Hadoopova gruča strežnikov omogoča učinkovito hrambo velike količine podatkov in ob tem zagotavlja zelo hiter dostop do podatkov. Pred Hadoopom so aplikacije za paralelno procesiranje imele težave z distribuiranjem izvajanja med strežniki v gruči. Glavna težava je bila v tem, da so strežniki imeli velike zahteve po dostopu do skupnega podatkovnega centra z zelo veliko I/O performanco. Hadoop je premaknil izvajanje programov k samim podatkom, kar je rešilo veliko performančnih izzivov, prav tako pa so aplikacije organizirane na način, da procesirajo podatke sekvenčno, kar onemogoča naključni dostop do podatkov in zmanjšuje I/O čase.
- Zanesljivost, samodejni preklon in razširljivost – v preteklosti so imele paralelne aplikacije velike težave z zanesljivostjo, kadar je prišlo do zamenjave ali premikov strežnikov ali gruče. Čeprav je zanesljivost posameznega računalnika zelo visoka, verjetnost okvare raste, kadar se povečuje velikost gruče. V velikih gručah, kjer je po več tisoč računalnikov, ni nič presenetljivega imeti okvare tudi na dnevni ravni. Zaradi teh težav je Hadoop načrtovan in implementiran, da okvare ne povzročijo nekonsistentnosti sistema in podatkov. Hadoop enostavno zazna okvaro in ponovi izvedbo z uporabo drugega strežnika. Prav tako pa podpora za razširljivost, ki je vgrajena v Hadoop, omogoča neopazno dodajanje in odstranjevanje strežnikov v gručo in njihovo uporabo za hrambo podatkov in procesiranje.

Podjetja danes uporabljajo Hadoop za reševanje številnih poslovnih problemov:

- Izboljšanje odkrivanja goljufij v bankah in kartičnih podjetjih – z uporabo analitičnih modelov na celotnem setu transakcij Hadoop zagotavlja preprečevanje goljufij in zlorab v skoraj realnem času.

- Marketinške analize družbenih omrežij – podjetja uporabljajo Hadoop za upravljanje blagovnih znamk, marketinške kampanje in zaščito blagovne znamke. S spremljanjem, zbiranjem in agregiranjem podatkov iz različnih internetnih virov, kot so blogi, oglasne deske, novice, tviti in objave na družbenih omrežjih, podjetja uporabljajo Hadoop, da izvlečejo informacije o svojih produktih, storitvah in konkurenci. Hadoop lahko uporabimo tudi za odkrivanje vzorcev in razkrivanje prihajajočih trendov, ki so pomembni za razumevanje njihovega poslovanja.
- Analiza nakupnih vzorcev za postavitev produktov – podjetja uporabljajo Hadoop za določitev najprimernejših produktov za prodajo v določenih fizičnih trgovinah, in sicer glede na lokacijo trgovine in nakupne vzorce populacije, ki živi v bližini trgovine.
- Prepoznavanje prometnih vzorcev za urbani razvoj – s spremljanjem prometa skozi različne čase v dnevu in z razkrivanjem prometnih vzorcev, lahko mestni načrtovalci določijo prometna ozka grla in sprejmejo odločitev, ali bo potrebna še kakšna dodatna cesta, da se izognejo prometnim zamaškom.
- Optimizacija vsebin in udejstvovanje – podjetja se vedno bolj fokusirajo na optimizacijo vsebin, ki so prilagojene različnim napravam in podpirajo različne formate vsebine.
- Omrežna analitika in mediacija – napredna analitika v realnem času na velikanski količini ustvarjenih podatkov omogoča podjetjem, da zmanjšajo operativne stroške in izboljšajo uporabniško izkušnjo v omrežju. Najpogosteje se uporablja transakcijske podatke, podatke o zmogljivosti omrežja, telefonske podatke in podatke iz naprav.
- Velike transformacije podatkov – z uporabo Hadoopa je New York Times uspel transformirati 4TB skeniranih člankov v 1,5 TB dokumentov v 24 urah. Nastalo je 11 milijonov PDF datotek, ustvarjenih iz člankov od leta 1851 do 1980, in sicer s pomočjo skeniranja slike iz originalnega časopisa.

Hadoop lahko klasificiramo kot ekosistem, ki je sestavljen iz več komponent, ki segajo od hrambe podatkov, integracije podatkov, procesiranja podatkov in specializiranih orodij za analizo podatkov. Hadoop ekosistem je sestavljen iz naslednjih komponent:

- Hadoop distribuirani datotečni sistem (Hadoop Distributed File System HDFS) je ena ključnih komponent Hadoop ekosistema. HDFS je mehanizem, s pomočjo katerega lahko distribuiramo veliko količino podatkov po več gruclah računalnikov. V HDFS se podatki zapišejo le enkrat in se nato lahko večkrat berejo za potrebe analitike. HDFS je prav tako temelj za delovanje vseh ostalih orodij.
- Algoritem MapReduce je glavno orodje za distribuirano in paralelno procesiranje podatkov z razbijanjem nalog v posamezne faze mapiranja (angl. mapping phases). Razvijalci za potrebe analitike napišejo MapReduce naloge in uporabijo podatke, shranjene v HDFS, ki omogoča hiter dostop do podatkov. Zaradi narave delovanja algoritma MapReduce ta pripelje procesiranje bližje k podatkom.
- Podatkovna baza HBase je stolpčno orientirana podatkovna baza NoSQL, zgrajena nad sistemom HDFS. HBase se uporablja za hitre I/O dostope do velikih količin podatkov. HBase za svoje upravljanje uporablja Zookeeper z namenom, da zagotavlja nemoteno delovanje komponent.

- Zookeeper je Hadoopova distribuirana koordinacijska storitev (angl. coordination service), ki je načrtovana, da deluje preko več gruč strežnikov. Zookeeper je visoko razpoložljiva storitev, ki se uporablja za upravljanje Hadoopovih operacij, številne komponente v Hadoop ekosistemu so odvisne prav od nje.
- Oozie je prilagodljiv sistem za načrtovanje delovnega toka (angl. workflow) in je integriran v Hadoopov ekosistem. Uporablja se za koordinirano izvajanje več nalog MapReduce. Oozie je sposoben upravljati znaten del kompleksnosti in njegovo osnovno izvajanje temelji na zunanjih dogodkih.
- Pig predstavlja abstrakcijo nad kompleksnostjo programiranja MapReduce. Platforma Pig vključuje izvedbeno okolje in skriptni programski jezik Pig Latin, ki se uporablja za analizo podatkovnih zbirk Hadoop. Njegov compiler prevede Pig Latin v sekvenco programov MapReduce.
- Hive je visokostopenjski programski jezik, ki se uporablja za izvajanje poizvedb na podatkih, ki so shranjeni v Hadoopu. Hive omogoča razvijalcem, ki niso večji programiranja MapReduce, da napišejo podatkovne poizvedbe, ki so potem prevedene v naloge MapReduce. Podobno kot Pig je tudi Hive razvit kot abstraktni nivo, vendar je bolj usmerjen k podatkovnim analitikom, ki so bolj večji SQL kot Java programiranja.

Ekosistem Hadoop ima prav tako nekatera orodja za integracijo z ostalimi informacijskimi sistemi:

- Sqoop je povezljivo orodje (angl. connectivity tool) za premik podatkov med relacijskimi podatkovni bazami, podatkovnimi skladišči in Hadoopom. Sqoop uporablja podatkovno bazo za opis sheme za importirane in eksportirane podatke in MapReduce za paralelno procesiranje.
- Flume je distribuirana, zanesljiva in visokodostopna storitev za učinkovito zbiranje in premikanje velikih količin podatkov iz individualnega računalnika na HDFS. Osnovan je na enostavni in fleksibilni arhitekturi ter omogoča pretakanje podatkovnih tokov, kar omogoča premik podatkov z več strežnikov znotraj podjetja v Hadoop.

Ekosistem Hadoop raste zelo hitro in ob glavnih komponentah prinaša nekatere nove možnosti in orodja:

- Whirr je skupina knjižnic, ki omogoča uporabnikom, da na enostaven način uporabijo gručo Hadoop na Amazon EC2, Rackspace ali katerekoli drugi virtualni infrastrukturi.
- Mahout je knjižnica za strojno učenje ter rudarjenje podatkov in omogoča MapReduce implementacijo popularnih algoritmov, ki se uporabljajo za grupiranje, regresijske teste in statistično modeliranje.
- BigTop je formalen proces in orodje za pakiranje in interoperabilno testiranje Hadoopovih podprojektov in povezanih komponent
- Ambari je projekt, ki se ukvarja s poenostavitvijo upravljanja Hadoopa z omogočanjem podpore z namestitvijo, upravljanjem in nadzorom gruče strežnikov [4].

Kljub popularnosti Hadoopa se zaradi omejenih možnosti interaktivnega delovanja in hitrih odzivnih časov vedno bolj uveljavljata Apache Spark in Flink, ki omogočata procesiranje podatkovnih tokov (angl. Stream Data Processing) v skoraj realnem času.

4. Digitalni marketing v obdobju Big Data in interneta stvari IoT

Big Data predstavlja ogromen obseg, visoko hitrost in veliko raznolikost informacijskih sredstev, ki zahtevajo stroškovno učinkovito in inovativno obliko procesiranja informacij za izboljšane vpoglede in odločanje (Gartner) [3].

Big Data je pojem, ki opisuje velik obseg ter visoke hitrosti kompleksnih in variabilnih podatkov, ki zahtevajo napredne tehnike in tehnologije, da omogočijo zajem, hrambo, distribucijo, upravljanje in analizo informacij (TechAmerica) [3].

Big Data ima moč in potencial, da preoblikuje celoten poslovni proces in poslovanje podjetij. V informacijski tehnologiji predstavlja naslednji val za razvoj inovacij, konkurenčnosti in produktivnosti ter prinaša revolucijo v znanosti. Big Data je sposoben povečati konkurenčnost podjetij s transformacijo procesov in spreminjanjem korporativnih ekosistemov. Raziskave so pokazale, da lahko trgovci povečajo povrnitev investicije ROI za 15–20% z uporabo Big Data analitike.

Do tega fenomena je prišlo predvsem zaradi široke uporabe mobilnih naprav, družbenih omrežij, kot so Facebook, YouTube in Twitter, ter koncepta interneta stvari IoT (angl. Internet of Things). Več milijard uporabnikov z uporabo pametnih telefonov sebe spremeni v podatkovni tok (angl. data stream), ki ga uporabljamo za napredno analitiko pri poslovanju podjetja. Prav tako se na področju gospodarstva z identifikacijo in sledenjem produktov z označevanjem RFID generira zelo veliko operativnih in strateških podatkov skozi celotno oskrbovalno verigo in čez vse industrije. Število produktov z oznako RFID je zraslo iz 1,3 milijarde v 2005 na 30 milijard v 2015. Podatke, ki so lahko strukturirani, polstrukturirani ali nestrukturirani, lahko pridobimo še iz številnih drugih kanalov in virov, kot so senzorji, sateliti, fotografije, video posnetki, click stream, telefonski in GPS-signali.

Pri Big Data ne smemo misliti samo na analitiko, ampak tudi na razvoj visokonivojskih veščin, ki omogočajo uporabo nove generacije IT-orodij in arhitekture za zajemanje podatkov iz različnih virov, njihovo shranjevanje, organiziranje, izvlečenje, analiziranje z namenom izdelave vrednostnih vpogledov (angl. valuable insights) in deljenje teh vpogledov s ključnimi deležniki v podjetju, za ustvarjanje konkurenčne prednosti, merjenje performanc in ustvarjanje dodane vrednosti. Podjetja lahko z uporabo Big Data v realnem času pridobijo pomembne informacije o svojih kupcih, optimizirajo oskrbovalne verige in človeške vire, izboljšajo finančne metrike in razvijejo vpoglede in poročila za sprejemanje odločitev [46].

Big Data lahko razumemo kot podatke, ki so preveliki, da bi jih lahko shranili v relacijsko podatkovno bazo in analizirali s klasičnimi statističnimi in analitičnimi orodji, zato analize zahtevajo masovno paralelno programsko opremo, ki se izvaja na več sto ali tisoč strežnikov.

Dodana poslovna vrednost, ki jo lahko prinese Big Data:

- Izdelava transparentnosti (angl. creating transparency), saj zmanjša čas vstopa na trg in izboljša kvaliteto poslovanja.
- Omogoča eksperimentiranje za raziskovanje potreb (angl. discover needs), izpostavi variabilnost (angl. expose variability) in izboljša performančnost.
- Segmentacija populacije za prilagojene akcije (angl. customize actions), saj omogoča izdelavo mikrosegmentov in prilagoditev ponudbe produktov in storitev, ki ustrezajo tem potrebam.

- Zamenjava in podpora pri človeškemu odločanju z avtomatiziranimi algoritmi, ki izboljšajo sprejemanje odločitev in zmanjšajo tveganja.
- Omogoča inoviranje novih poslovnih modelov, produktov in storitev.

Pri Big Data je zelo pomembna kvaliteta podatkov, ki je ključna za doprinos dodane vrednosti podjetju. Pomanjkljivi, slabi ali nepravilni podatki imajo zelo malo potenciala, da pomagajo menedžerjem pri sprejemanju pravih odločitev, ampak bodo po nepotrebnem porabljali organizacijske resurse. Slaba kvaliteta podatkov lahko pride iz odvečnih ali starih aplikacij in podatkovnih baz, kar povečuje stroške hranjenja podatkov in otežuje dostop ter njihovo uporabo. Čeprav povečana količina podatkov lahko izboljša poslovno vrednost podjetja, vedno obstaja nevarnost odvečnih, nepravilnih in podvojenih podatkov, ki lahko spodkopljejo dostavo storitev, vpogledov in procese odločanja. Slaba kvaliteta podatkov in neučinkovito upravljanje s podatki sta ključna izziva za Big Data. Vodstvo podjetja mora zagotoviti varno ravnanje z individualno in organizacijsko zasebnostjo v kontekstu Big Data, kar pomeni, da je potrebno individualne in poslovne podatke o svojih kupcih ustrezno varovati in se jih ne sme razkrivati tretjim osebam. To predstavlja veliko preizkušnjo za vodstvo in vse zaposlene v podjetju. Današnja tehnologija je namreč spremenila povprečnega potrošnika v nenehni generator tako tradicionalnih, strukturiranih in transakcijskih podatkov kot tudi bolj sodobnih, nestrukturiranih vedenjskih podatkov. Magnituda generiranih podatkov, neusmiljena hitrost, s katero podatki nastajajo, in raznoliko bogastvo podatkov preoblikujejo procese odločanja in poslovanje podjetja.

Čeprav se v veliko podjetjih Big Data obravnava kot nova oblika kapitala na trgu, veliko podjetij ni uspelo izkoristiti njegovih prednosti. Za ustvarjanje dobička in dodane vrednosti iz tega kapitala morajo podjetja zagotoviti primerna fizična, človeška in organizacijska sredstva. Ko podatki postajajo večji, bolj kompleksni in nepojasneni, povzročajo težave pri zaposlenih zaradi omejene mentalne zmogljivosti ljudi pri razvozlavanju in interpretaciji neznanega okolja. Big Data omogoča analitikom, da identificirajo vzorce v podatkih brez oblikovanja hipotez in takšne poizvedbe zahtevajo manj zanašanja na obstoječo znanje in se bolj fokusirajo na tisto, kar je neznano [50].

4.1 Dimenzije in karakteristike Big Data

Big Data oblikuje 5 ključnih dimenzij in karakteristik:

- Obseg (angl. Volume) – obseg Big Data se trenutno meri v petabajtih, eksabajtih ali zetabajtih. Pri Walmartu ocenjujejo, da vsako uro generirajo 2,5 petabajtov podatkov o uporabnikih. Ker so podjetja pred nenehnim izzivom povečanja obsega podatkov, se ocenjuje, da se bo globalni trg za programsko in strojno opremo ter storitvami za shranjevanje in analiziranje velike količine podatkov podvojil vsake dve leti. K eksplozivni rasti obsega podatkov bo največ prispeval internet stvari (IoT), kjer se bodo pridobivali podatki iz avtomobilov, igrac, naprav, turbin ter drugih senzorjev in naprav. Pričakuje se, da bo do leta 2020 v internet povezanih več kot 26 milijard naprav [50]. Definicija Big Data je glede na obseg relativna in se razlikuje glede na dejavnike, kot sta čas in tip podatka. Kar se danes šteje kot Big Data, v prihodnosti to ne bo tako, saj se skladiščne zmogljivosti povečujejo, kar omogoča, da se shranjujejo vedno večje zbirke podatkov [3].

- Hitrost (angl. Velocity) – druga dimenzija Big Data je neusmiljena hitrost ustvarjanja novih podatkov. Hitrost se nanaša na stopnjo, pri kateri se podatki generirajo, in hitrost, pri kateri se ti podatki analizirajo in nato sprejemajo odločitve in ukrepi. Širjenje uporabe digitalnih naprav, kot so pametni telefoni in senzorji, je pripeljalo do izjemne stopnje ustvarjanja novih podatkov in zahteva vedno večje potrebe po analitiki v realnem času in načrtovanje na podlagi dokazov. Podatki, ki izhajajo iz mobilne naprave in se pretakajo skozi mobilne aplikacije, proizvedejo veliko količino informacij, ki se lahko uporabijo za izdelavo personaliziranih ponudb v realnem času. Glede na naraščajočo priljubljenost pametnih telefonov bodo trgovci v kratkem imeli opravka z več sto tisoč ali milijon izvorov podatkov (angl. streaming data sources), ki bodo zahtevali uporabo analitike v realnem času. Tradicionalni sistemi za upravljanje podatkov niso sposobni rokovati z velikimi podatkovnimi zbirkami v realnem času in tukaj igra Big Data pomembno vlogo [3].
- Raznolikost (angl. Variety) – se nanaša na strukturno heterogenost v naboru podatkov. Veliko različnih virov podatkov zagotavlja bogato raznolikost podatkov, ki presegajo tradicionalne podatke iz preteklosti. Glavna razlika med sodobnimi Big Data podatki in tradicionalnimi podatki je premik iz tradicionalnih transakcijskih podatkov v nestrukturirane vedenjske podatke. Med strukturirane podatke, ki štejejo nekje 5 % vseh podatkov, štejemo podatke iz senzorjev in skenerjev, datotek in podatkovne baze. Nestrukturirani podatki vključujejo tekstualne podatke, kot so blogi, kratka sporočila in netekstualne podatke, kot so videi, slike in zvočni zapisi. Veliko nestrukturiranih podatkov se zajame tudi preko družbenih omrežij, kjer posamezniki delijo osebne in vedenjske podatke s prijatelji, družino ali podjetji [50]. Visoka stopnja raznolikosti, ki definira Big Data, ni nujno, da je novost. Podjetja so že v preteklosti kopičila nestrukturirane podatke iz internih virov (podatki iz senzorjev) in zunanjih virov (družbena omrežja). Inovativni vidik je pojav novih tehnologij za upravljanje podatkov in analitiko, ki omogoča organizacijam, da izkoristijo podatke v svojih poslovnih procesih. Tehnologije za prepoznavo obrazov recimo omogočajo fizičnim trgovcem, da pridobijo inteligentne podatke o prometu v trgovini, starosti in spolu svojih kupcev in njihove vzorce premikanja v trgovini. Te neprecenljive informacije lahko podjetja izkoristijo pri odločanju glede promocije produktov, umestitve produktov in za kadrovanje. V spletni trgovini tok klikov (angl. ClickStream) zagotavlja bogate informacije o vedenju kupca in vzorcih brskanja, s katerimi lahko izboljšamo obliko in načrt spletne strani ali implementiramo učinkovito navzkrižno prodajo in personalizirane produkte s pomočjo priporočilnih sistemov [3].
- Verodostojnost (angl. Veracity) – zagotavlja potrebo po zavedanju o kvaliteti podatkov, saj niso vsi podatki o potrošniku pravilni in natančni [50]. Verodostojnost predstavlja vsebovano nezanesljivost v nekaterih virih podatkov. Čustva strank na družbenih omrežjih so recimo negotova, saj jih povzročajo človeške sodbe, ki imajo različne motive, želje, interese in etična načela. Potreba po obravnavi nenatančnih in negotovih podatkov je še en vidik Big Data, kjer se uporabljajo posebna orodja in analitika, razvita posebej za upravljanje in rudarjenje negotovih podatkov [3].
- Vrednost (angl. Value) – vedno večja količina podatkov nam mora prinesiti vrednost, zato je potrebno, da izločimo nepotrebne in neustrezne podatke. Preostali primerni podatki morajo biti dragoceni za pripravo in pridobitev

vpogledov ter poročil in domenskih interpretacij. Vrednost je dosežena z izboljšanim sprejemanjem odločitev, ki je omogočen s strani Big Data. Pridobitev vrednosti iz Big Data podatkov lahko povzroči trajnostno ali začasno konkurenčno prednost [50].

Obstajajo štiri vrste Big Data poslovne analitike:

- Deskriptivna – pove, kaj se dogaja sedaj glede na pridobljene vhodne podatke. Rezultat takšne analize je največkrat analitična nadzorna plošča, ki uporablja podatke v realnem času in pošilja obvestila po e-pošti ali SMS.
- Diagnostična – omogoča vpogled na pretekle performance z namenom določitve, kaj se je zgodilo in zakaj. Rezultat je pogosto analitična nadzorna plošča.
- Prediktivna – razkriva verjetne scenarije, kaj bi se lahko zgodilo. Rezultat je največkrat prediktivna napoved.
- Preskriptivna – razkriva, kakšne akcije moramo izvesti v prihodnje. To je najdragocenejša analiza in ponavadi kot rezultat nastanejo pravila in priporočila za naslednji korak.

Poslovna analitika je tehnika, ki pridobi uporabne informacije o uporabniku in razkrije skrita vedenja iz Big Data podatkov. Prav tako pa zagotavlja veliko pomoč pri sprejemanju odločitev in napovedovanju vpliva sprejetih odločitev [38].

4.2 Big Data Analitika

Podatki Big Data so popolnoma brez vrednosti, če obvisijo v nekem vakuumu. Njihova potencialna vrednost je odklenjena, kadar predstavljajo podlago za sprejemanje odločitev. Da podjetja lahko omogočijo odločanje na podlagi podatkov in dokazov, morajo imeti vzpostavljene učinkovite procese, ki spremenijo velik obseg hitro premikajočih in raznolikih podatkov v pomembne in koristne vpoglede in poročila [3].

Analitične tehnike Big Data za strukturirane in nestrukturirane podatke so:

- tekstovna analitika (angl. Text analytics),
- avdio analitika (angl. Audio analytics),
- video analitika (angl. Video analytics),
- analitika družbenih medijev (angl. Social media analytics).

4.2.1 Tekstovna analitika

Tekstovna analitika ali tekstovno rudarjenje se nanaša na tehnike, ki izvlečejo informacije iz tekstovnih podatkov. Tekstovna analitika vključuje statistično analizo, računsko lingvistiko in strojno učenje. Tekstovna analitika omogoča podjetjem, da spremenijo velike količine človeško generiranih tekstov in vsebin v smiselne povzetke, ki omogočajo odločitve na podlagi dokazov. Tekstovna analitika lahko na primer napove vrednost delniškega trga na podlagi informacij, izvlečenih iz časopisov. Metode tekstovne analitike so:

- Izvlečenje informacij (angl. Information extraction) – s to tehniko izvlečemo strukturirane podatke iz nestrukturiranih podatkov. Ti algoritmi lahko iz zdravniških receptov izvlečejo strukturirane informacije, kot so ime zdravila,

doza in pogostost uporabe. Algoritmi imajo dve podopravi: prepoznavanje entitete (angl. Entity Recognition ER) in izvlečenje razmerij (angl. Relation Extraction RE). ER poišče imena in tekste ter jih klasificira v preddefinirane kategorije, kot so oseba, datum, lokacija in organizacija. RE poišče in izvleče semantična razmerja med entitetami, kot so osebe, organizacije in zdravila v tekstu.

- Tekstovni povzetki (angl. Text summarization) – ta tehnika avtomatsko proizvede jedrnat povzetek enega ali več dokumentov. Nastali povzetek vključuje ključne informacije v originalnem tekstu, npr. časopisih, znanstvenih člankih, marketinških vsebinah, e-sporočilih in blogih. Tehnika sledi dvema pristopoma, izvlečenju in abstrakciji. Pri tehniki izvlečenja povzetka je povzetek narejen iz enot originalnega teksta. Proizveden povzetek je podmnožica informacij originalnega dokumenta. Formuliranje povzetka vključuje določitev najpomembnejših enot teksta in njihovo skupno povezovanje. Pomembnost tekstovnih enot je ocenjena z analizo njegove lokacije in pogostosti v tekstu. Ta tehnika ne zahteva razumevanje teksta. V nasprotnem primeru tehnika abstraktnega povzetka vključuje izvlečenje semantičnih informacij iz teksta. Povzetek vključuje tekstovne enote, ki niso nujno prisotne v originalnem tekstu. Z namenom razčlenitve originalnega teksta iz izdelave povzetka ta tehnika vključuje napredno tehniko naravnega procesiranja jezika (angl. Advanced Natural Language Processing NLP). Abstraktne tehnike tako izdelajo skladnejše povzetke kot tehnike izvlečenja, vendar je te lažje sprejeti v organizaciji, še posebej na področju Big Data.
- Odgovarjanje na vprašanja (angl. Question answering QA) – ta tehnika zagotavlja odgovore na vprašanja v naravnem jeziku. Applova Siri in IBM Watson sta primera komercialnih sistemov QA. Ti sistemi se uporabljajo v zdravstvu, finančni industriji, marketingu in izobraževanju. Podobno kot abstraktni povzetek sistem QA temelji na kompleksnih tehnikah NLP. Tehnike QA se dodatno razdelijo na podkategorije: pristop na pridobivanju informacij (angl. Information retrieval IR), pristop, temelječ na znanju, in hibridni pristop. QA, temelječ na IR-pristopu, ima pogosto tri podkomponente. Prva komponenta omogoča procesiranje vprašanj (angl. question processing) in se uporablja za določitev podrobnosti vprašanja, tipa vprašanja, fokusa vprašanja, tipa odgovora in izdelavo poizvedbe. Druga komponenta omogoča procesiranje dokumentov (angl. document processing) in se uporablja za pridobivanje pomembnih informacij iz seta dokumentov z uporabo poizvedbe, generirane v prvem koraku. Tretja komponenta omogoča procesiranje odgovora (angl. answer processing) in se uporablja za izdelavo izvlečkov iz primernih odgovorov, ki so izhod iz prejšnjega koraka. Izvlečki se razvrstijo in algoritem vrne odgovor z največjo pomembnostjo (angl. rank) kot izhod iz sistema QA. Sistemi QA, ki temeljijo na bazi znanja, ustvarijo semantični opis vprašanja, ki se potem uporabi za poizvedbo strukturiranih virov. Ti sistemi so zlasti uporabni na omejenih področjih, kot so turizem, medicina ali transport, kjer ne obstaja velik obseg prednapisanih dokumentov. Applova Siri je primer sistema QA, ki izkorišča pristop z bazo znanja, IBM Watson pa je primer hibridnega sistema QA, kjer je vprašanje semantično analizirano, odgovori pa so ustvarjeni s pomočjo IR-metode.
- Sentimentalna analiza (angl. Sentiment analysis) ali rudarjenje mnenj – je tehnika, ki analizira tekste z mnenji uporabnikov, ki vsebujejo informacije glede produktov, podjetij, oseb ali dogodkov. Podjetja v vedno večji meri zajemajo podatke o čustvih svojih strank in ti podatki se uporabljajo na

področju marketinga, financ, politike in v družbenih vedah. Sentimentalne analize se delijo naprej v tri podskupine: stopnja dokumenta (angl. Document level), stopnja stavka (angl. Sentence level) in stopnja vidika (angl. Aspect level). Tehnika stopnje dokumenta določa, ali celoten dokument izraža negativna ali pozitivna čustva. Tehnika stopnje stavka poskuša določiti polarnost enotnega čustva o poznani entiteti, ki je izražena v enem stavku. Ta tehnika mora najprej ločiti subjektivne stavke od objektivnih in zato je ta tehnika veliko kompleksnejša od tehnike stopnje dokumenta. Tehnika stopnje vidika prepozna vse občutke znotraj dokumenta in identificira vidik entitete, na katero se navezuje vsak stavek. Uporabniška ocena in komentar produkta na primer ponavadi vsebujeta mnenje o različnih vidikih in lastnostih produkta. Z uporabo te tehnike lahko trgovec pridobi dragocene informacije o različnih lastnostih produkta, ki bi se izgubile, če bi občutke klasificirali le glede na polarnost [3].

4.2.2 Avdio analitika

Avdio analitika analizira in izvleče informacije iz nestrukturiranih avdio podatkov. Kadar se uporablja pri človeškem govoru, se pogosto naslavlja tudi kot analitika govora (angl. Speech analytics). Trenutno se avdio analitika največ uporablja v klicnih centrih in zdravstvu. Klicni centri uporabljajo avdio analitiko za učinkovito analizo tisoč ali tudi milijonov ur posnetih klicev. Te tehnike pomagajo izboljšati uporabniško izkušnjo, ocenjujejo uspešnost agenta, povečujejo prodajo, spremljajo skladnost z različnimi politikami in pravilniki, kot je pravilnik o zasebnosti in varnosti, pridobijo vpogled v vedenje strank ali identificirajo težave s produkti ali storitvami. Avdio analitični sistemi so lahko načrtovani, da analizirajo klice v živo ali za nazaj, oblikujejo prodajna priporočila glede na strankine pretekle in trenutne interakcije ali v realnem času zagotavljajo povratne informacije agentom. V zdravstvu avdio analitika pomaga diagnosticirati in zdraviti nekatere bolezni, ki vplivajo na pacientove komunikacijske vzorce, kot so na primer depresija, shizofrenija ali rak. Avdio analitika lahko pomaga analizirati tudi dojenčkov jok, ki lahko vsebuje informacije o dojenčkovem zdravju in čustvenem stanju.

Analitika govora uporablja dva splošna tehnološka pristopa: pristop na osnovi prepisa (angl. transcript-based) in pristop na osnovi fonetike (angl. phonetic-based). Pristop na osnovi prepisa je dvostopenjski proces, ki vključuje indeksiranje in iskanje. V prvi fazi poskuša prepisati vsebino avdio govora v tekst. To se izvede preko algoritmov avtomatske prepoznave govora (angl. automatic speech recognition ASR), ki upari zvok z besedami. Besede so identificirane na podlagi preddefiniranega slovarja – če sistem v slovarju ne najde natančnega ujemanja, vrne najpodobnejši izraz. Izhod iz sistema je indeksirana datoteka, ki omogoča iskanje in vsebuje informacije o sekvenci besed v govoru. V drugi fazi so potem uporabljena standardna orodja za iskanje izrazov v indeksirani datoteki.

Fonetični pristop dela z zvoki ali fonemi. Fonemi so zaznavne različne enote zvoka v določenem jeziku, ki razlikujejo eno besedo od druge. Fonetični pristopi so prav tako sestavljeni iz dveh faz, iz fonetičnega indeksiranja in iskanja. V prvi fazi sistem prevede vhodni govor v sekvenco fonemov, kar je v nasprotju s pristopom prepisa govora, kjer se vhodni govor pretvori v sekvenco besed. V drugi fazi sistem poišče fonetično ujemanje z iskalnim izrazom [3].

4.2.3 Video analitika

Video analitika, znana tudi kot analiza video vsebine (angl. video content analysis VCA), vključuje različne tehnike za spremljanje, analizo in izvečenje pomembnih informacij iz video toka (angl. video stream). Za video analizo se uporabljajo različne tehnike za procesiranje v živo ali za procesiranje že posnetih videov. Zaradi povečane razširjenosti varnostnih kamer CCTV in naraščajoče popularnosti platform za deljenje video vsebin ter družbenih omrežij se je v zadnjem času zelo povečala uporaba računalniške video analize. Glavni izziv video analitike je ogromna velikost video podatkov, saj če gledamo iz perspektive, da je ena sekunda visoko ločljivega videa enakovredna 2000 stranem teksta, v teh primerih nastanejo ogromne količine podatkov. Na YouTube se naloži več kot 100 ur video vsebin vsako minuto. Big Data tehnologije lahko obrnejo te izzive v priložnost, saj lahko avtomatično presejejo video podatke in pripravijo vpogleds iz več tisoč ur video posnetkov. Primarna uporaba video analize v zadnjih letih je bila na področju avtomatizacije varnosti in v nadzornih sistemih. Zaradi velikih stroškov delovne sile naj bi bili nadzorni sistemi s pomočjo varnostnikov manj učinkoviti kot avtomatizirani sistemi. Na podlagi Hakeemove raziskave varnostno osebje ni sposobno biti fokusirano na nadzorne naloge več kot 20 minut. Video analiza lahko uspešno in učinkovito izvaja nadzorne funkcije, kot je odkrivanje kršitev na omejenih območjih, identificira odstranjene ali zapuščene objekte brez nadzora, zazna postopanje na specifičnih področjih, prepozna sumljive aktivnosti in zazna nedovoljene posege v kamero. Na podlagi zaznave grožnje lahko nadzorni sistem v realnem času obvesti varnostno osebje ali izvede avtomatsko akcijo, kot so zvočni alarm, zaklepanje vrat ali prižiganje luči.

Podatki, pridobljeni iz kamer CCTV v trgovinah, se lahko uporabijo za poslovno analitiko. Najpogosteje se ti podatki uporabljajo v marketingu in pri poslovanju podjetja, kjer lahko pametni algoritmi zbirajo demografske podatke o kupcih, kot so starost, spol in narodnost. Prav tako lahko štejejo število obiskovalcev, merijo čas, kako dolgo so ostali v trgovini, zaznajo njihove vzorce premikanja, merijo njihov čas mirovanja na različnih področjih in spremljajo vrste v realnem času. Iz tega lahko pridobimo dragocene vpogleds in poročila za sprejemanje odločitev glede umestitve produktov, cen produktov, optimizacije asortimana, načrtovanje promocije, navzkrižne prodaje, optimizacije postavitve produktov in kadrovanja. Drugo potencialno področje video analitike v trgovinah je proučevanje nakupnega vedenja skupin. Med člani družine, ki nakupujejo skupaj, ima le en član te družine stik s trgovcem pri blagajni, kar povzroči, da tradicionalni sistemi za programe zvestobe spregledajo in izgubijo podatke o nakupovalnem vzorcu ostalih članov. Video analiza lahko pomaga trgovcem obravnavati izgubljene priložnosti z zagotavljanjem informacij o velikosti skupine, demografskih podatkih skupine in nakupovalnih navadah posameznega člana skupine.

Avtomatsko video indeksiranje je še eno področje video analitike. Razširjen pojav online in offline video vsebin je poudaril potrebo po indeksiranju multimedijskih vsebin za enostavno iskanje in pridobivanje informacij. Indeksiranje videa se lahko izvede na različne načine glede na različne ravni razpoložljivih informacij v videu, vključno z metapodatki, glasbo, prepisom podatkov in vizualne vsebine videa. Pri pristopu z meta podatki se uporablja relacijska podatkovna baza za iskanje in pridobivanje video posnetka na podlagi meta podatkov. Avdio analitika in tekstovna analitika se lahko uporabita za analizo zvoka, glasbe ali prepis govora. Za vzpostavitev arhitekture za video analizo se uporabljata dva pristopa, strežniška (angl. server based) arhitektura in robna (angl. edge based) arhitektura. Pri strežniški

arhitekturi je video zajet preko kamere in preusmerjen nazaj na centralni in namenski strežnik, ki izvaja video analizo. Zaradi omejitve pasovne širine je video ponavadi stisnjen z zmanjšanjem števila sličic (angl. frames) ali resolucije slike, kar lahko vpliva na natančnost analiz. Pri robni arhitekturi se analitika izvaja na robu sistema, to je lokalno na surovih podatkih, zajetih direktno iz kamere. Prednost te arhitekture je v tem, da je za analizo na voljo celotna video vsebina, kar omogoča učinkovitejše vsebinske analize. Žal so ti sistemi dražji za vzdrževanje in imajo manjšo moč procesiranja [3].

4.2.4. Analitika družbenih medijev

Analitika družbenih medijev se nanaša na analizo strukturiranih in nestrukturiranih podatkov iz različnih kanalov družbenih medijev. Družbeni mediji so širok pojem, ki vključujejo različne spletne in mobilne platforme, ki omogočajo uporabnikom ustvarjanje in deljenje vsebin. Družbene medije lahko razdelimo na različne kategorije:

- družbena omrežja (Facebook, LinkedIn)
- blogi (Blogger, WordPress)
- mikroblogi (Twitter, Tumblr)
- družbene novice (Digg, Reddit)
- družbeni zaznamki (Delicious, StumbleUpon)
- deljenje medijskih vsebin (Instagram, YouTube)
- enciklopedije (Wikipedia, WikiHow)
- vprašanja in odgovori QA (Answers, Ask)
- ocenjevanje in komentiranje (Yelp, TripAdvisor)

Čeprav prve raziskave družbenih omrežij segajo že v zgodnja 20. leta prejšnjega stoletja, se je današnji način analize družbenih medijev pojavil šele po prihodu Web 2.0 v začetku leta 2000. Raziskave znotraj analize družbenih medijev se dotikajo več področij od psihologije, sociologije, antropologije, računalništva, matematike, fizike do ekonomije. Analitika družbenih medijev se danes največ uporablja na področju marketinga.

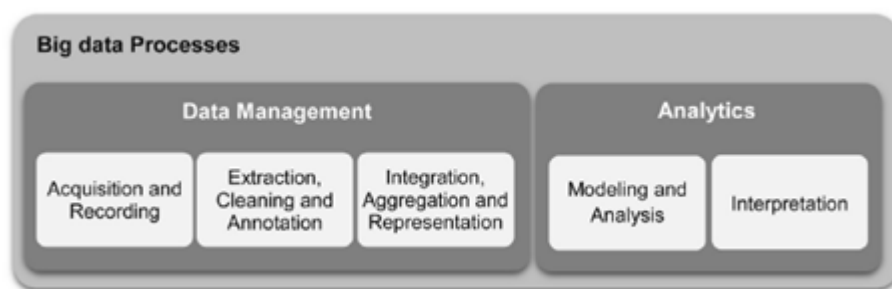
Analitiko družbenih medijev lahko razdelimo na dve skupini:

- Analiza vsebine (angl. Content based) se fokusira na podatke, objavljene s strani uporabnika na družbenih medijih, kot so povratne informacije, ocene produktov, slike in videi. Takšna vsebina je ponavadi obsežna, nestrukturirana, balastna in dinamična. Za pridobitev vpogledov in poročil iz teh podatkov se lahko uporabi tekstovna, avdio ali video analiza.
- Strukturna analiza (angl. Structure based) se ukvarja s sintezo strukturnih atributov družbenega omrežja, s pomočjo katere izvleče informacije iz razmerij med sodelujočimi entitetami. Struktura družbenega omrežja je modelirana skozi skupino vozlišč (angl. nodes) in robov (angl. edge), ki predstavljajo uporabnike in njihova razmerja. Model lahko vizualiziramo kot graf, sestavljen iz vozlišč in robov. Najbolj značilna grafa sta družbeni graf (angl. social graph) in aktivnostni graf (angl. activity graph). V družbenem grafu rob med paroma vozlišč pomeni, da obstaja povezava (prijateljstvo) med ustreznima entitetama. Z rudarjenjem teh grafov lahko identificiramo skupnosti uporabnikov. Pri aktivnostnem grafu rob predstavlja dejansko interakcijo med paroma vozlišč. Interakcije vključujejo izmenjavo informacij, kot so všečki, ocene in komentarji. Aktivnosti grafi nam dajo več dragocenih vpogledov, saj je

aktivnostna povezava pomembnejša za analitiko kot zgolj informacija o povezavi med njima [3].

V zadnjih letih so se pojavile različne tehnike za izvlačenje informacij iz strukture družbenih omrežij:

- Odkrivanje skupnosti (angl. Community detection) s pomočjo analize iz omrežja izvleče implicitne skupnosti uporabnikov. Za spletna družbena omrežja skupnost pomeni podmnožico uporabnikov, ki veliko bolj sodelujejo in so povezani med seboj kot s preostalim omrežjem. Ker so družbena omrežja sestavljena iz več milijonov ali milijard vozlišč, nam odkrivanje skupnosti pomaga raziskati strukturo velikih omrežij. Ti podatki nam potem pomagajo pri odkrivanju obstoječih vedenjskih vzorcev in napovedujejo nove nastajajoče lastnosti omrežja. Odkrivanje skupnosti je podobno grupiranju in omogoča podjetjem, da razvijejo učinkovitejše priporočilne sisteme.
- Analiza družbenega vpliva (angl. Social influence analysis) se nanaša na tehnike, ki se ukvarjajo z modeliranjem in ocenjevanjem vpliva posameznikov in njihovih povezav v družbenem omrežju. Vedenje uporabnika v družbenem omrežju je v veliki meri pod vplivom vedenja njegovih prijateljev, družinskih članov, sodelavcev in ostalih uporabnikov. Z analizo družbenega vpliva lahko ocenimo uporabnikov vpliv na ostale uporabnike, določimo moč povezav in odkrijemo vzorce difuzije vpliva v omrežju. Ta analiza je zelo primerna za viralne marketinške akcije in za krepitev blagovne znamke.
- Napovedovanje povezav (angl. Link prediction) rešuje problem napovedovanja bodočih povezav med obstoječimi vozlišči v omrežju. Struktura družbenih omrežij ni statična in neprestano raste z nastankom novih vozlišč in robov, zato je ključno, da dobro razumemo in napovemo nadaljnjo dinamiko omrežja. Te tehnike lahko za neko določeno obdobje napovejo pojav interakcije, sodelovanja ali vpliva med entitetami v omrežju. V biologiji se te tehnike uporabljajo za odkrivanje povezav v bioloških omrežjih, na področju varnosti se uporabljajo za odkrivanje potencialnih teroristov ali kriminalcev. Na področju spletnih družbenih medijev se uporabljajo predvsem za razvoj priporočilnih sistemov kot so Facebookovo priporočilo »Osebe, ki jih mogoče poznaš«, YouTube priporočilo »Priporočeno za tebe« ali priporočila na Netflixu in Amazonu [3].

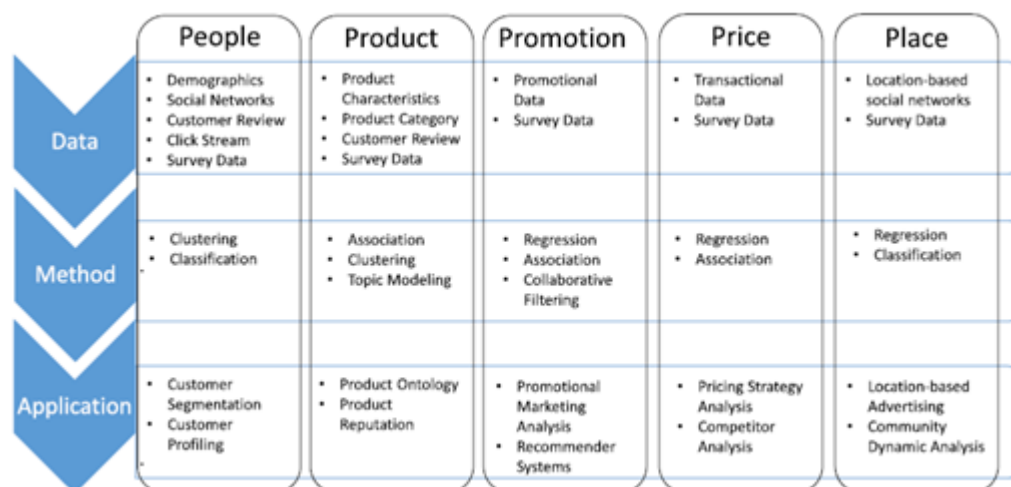


Slika 7: Proces izvlečenja informacij in vpogledov iz Big Data [3]

4.3 Marketinška analitika

Marketinška analitika, ki obravnava marketinški vidik poslovne analitike, se je tradicionalno zanašala na marketinške raziskave z namenom razumevanja nakupnih navad svojih kupcev in za izboljšanje svojih produktov. Z uporabo analitike Big Data lahko strateške marketinške odločitve sprejemamo v realnem času s pomočjo rudarjenja podatkov. Marketinški miks je zelo poznano marketinško ogrodje, ki identificira ključne komponente marketinških aktivnosti in odločitev [47].

Ocenjuje se, da lahko trgovec, ki v celoti izkorišča moč analitike Big Data, poveča dobiček iz poslovanja za 60 %. Z izkoriščanjem novih priložnosti, kot so lokacijske storitve, lahko marketinška analitika Big Data ponudi velik potencial za nove prihodke [25].



Slika 8: Marketinški miks analitičnih tehnik za upravljanje podatkov Big Data [47]

4.4 Internet stvari IoT

Internet stvari (angl. Internet of Things IoT) je nov tehnološki trend, ki predstavlja globalno mrežo povezanih strojev in naprav, ki so sposobni medsebojne interakcije. IoT je prepoznano kot eno od najpomembnejših tehnoloških področij prihodnosti in pridobiva pozornost raznoraznih industrij. Podjetja lahko iz IoT pridobijo dodano vrednost, ko povežejo stroje in naprave med seboj in jih integrirajo z ERP-sistemom, CRM-sistemom za podporo strankam in poslovno analitiko. Gartner napoveduje, da bo do leta 2020 v omrežje povezanih 26 milijard naprav, kar predstavlja veliko rast glede na 0,9 milijarde naprav v letu 2009. Z dostopnostjo podatkov, poročil in vpogledov, ki so na voljo vsem partnerjem v oskrbovalni verigi, lahko v realnem času vidijo, kako oskrbovalna veriga deluje in jo po potrebi optimizirajo. IoT spreminja poslovne procese z zagotavljanjem natančnih informacij v realnem času za proizvodnje linije, skladišča, logistiko, postavitve na polico in prodajo. Nekatera podjetja, kot so UPS in John Deere, že uporabljajo tehnologijo IoT za sledenje voznemu parku, za zmanjševanje stroškov in izboljšanje učinkovitosti vzdrževanja. Ob proizvajalcih tudi številna druga storitvena podjetja sprejemajo IoT z namenom povečanja prihodkov skozi izboljšane produkte in storitve. Disnijeve zapeljivost

MagicBand ima čip RFID, ki služi kot vstopnica in je povezana s podatkovno bazo strank CRM [16].

Grozd evropskega raziskovalnega projekta za internet stvari (CERP-IoT) je definiral IoT kot globalno dinamično in samostojno omrežno infrastrukturo, ki temelji na standardnih in komunikacijskih protokolih, kjer imajo fizične in virtualne stvari (angl. Things) identiteto, fizične lastnosti, virtualno osebnost ter uporabljajo inteligentne vmesnike, ki so nevidno integrirani v informacijsko omrežje [10].

Pet IoT tehnologij se najpogosteje uporablja za postavitve uspešne produktne ali storitvene IoT platforme:

- radio frekvenčna identifikacija (angl. radio frequency identification RFID)
- omrežja brezžičnih senzorjev (angl. wireless sensor networks WSN)
- vmesna oprema (angl. middleware)
- računalništvo v oblaku (angl. cloud computing)
- programska oprema IoT (angl. application software) [16]

Radio frekvenčna identifikacija omogoča avtomatično identifikacijo in zajem podatkov z uporabo radio valov, značk (angl. tag) in čitalnika. Na značko lahko shranimo več podatkov kot na tradicionalno črtno kodo. Poznamo tri tipe značk: pasivne značke RFID, ki se zanašajo na radio frekvenčno energijo, preneseno iz čitalnika na značko in ne uporabljajo baterij za pogon. Uporabo teh značk lahko najdemo v oskrbovalni verigi, potnih listih, elektronskem cestninjenju in spremljanju produktov. Aktivne značke RFID imajo lastno baterijsko napajanje in lahko same sprožijo komunikacijo s čitalnikom. Aktivne značke lahko imajo zunanje senzorje za spremljanje temperature, pritiska, kemikalij in drugih pogojev in se uporabljajo v proizvodnji, bolnišnicah ter laboratorijih. Polpasivne značke uporabljajo baterijo za napajanje mikročipa, medtem ko za komunikacijo uporabljajo energijo iz čitalnika.

Omrežja brezžičnih senzorjev so sestavljena iz prostorsko porazdeljenih avtonomnih naprav, opremljenih s senzorji za spremljanje fizičnih ali okoljskih pogojev. Sodelujejo lahko z identifikacijskimi sistemi RFID in sledijo statusu naprav ter pridobivajo informacije o njihovi lokaciji, temperaturi in premikanju. WSN se najpogosteje uporablja na področju logistike hladne verige, ki omogoča toplotne in zamrznjene metode pakiranja za transport temperaturno občutljivih produktov. WSN se uporablja tudi pri preventivnem vzdrževanju in pri sistemih za sledenje.

Vmesna oprema je integracijska platforma med različnimi programskimi aplikacijami, ki zakrije posamezne specifične različnih tehnologij. Kompleksno porazdeljena infrastruktura IoT z velikim številom različnih naprav zahteva poenostavitve razvoja novih aplikacij in storitev, zato je uporaba vmesne opreme idealna za razvoj aplikacij IoT.

Računalništvo v oblaku je model dostopa na zahtevo do skupnih nastavljivih virov, kot so računalniki, omrežja, strežniki, aplikacije, storitve, programska oprema in se lahko uporablja kot Infrastruktura kot storitev (IaaS) ali Programska oprema kot storitev (SaaS). Veliko aplikacij IoT zahteva ogromno prostora za shranjevanje podatkov, veliko procesorsko moč za omogočanje odločitev v realnem času ter visokohitrostno širokopasovno omrežje za pretok podatkov, avdia ali videa.

Če naprave in omrežja zagotavljajo fizično povezljivost, aplikacije IoT omogočajo interakcijo naprava-naprava in človek-naprava na zanesljiv in robusten način. Aplikacije IoT na napravah morajo zagotoviti sprejem podatkov in sporočil ter morajo na njih odreagirati pravočasno in pravilno. Za aplikacije IoT je pomembno, da uporabljajo neko osnovno inteligenco, da lahko naprave samostojno spremljajo okolje, identificirajo probleme, komunicirajo med seboj in poskušajo same rešiti problem brez človeškega posredovanja. Aplikacije IoT lahko delimo na tri kategorije: [16]

- spremljanje in nadzor (angl. monitoring and control)
- Big Data in poslovna analitika
- deljenje informacij in sodelovanje

Sistemi za spremljanje in nadzor zbirajo podatke o performančnosti opreme, porabi energije in okoljskih pogojih ter omogočajo menedžerjem in avtomatiziranim krmilnikom, da neprestano spremljajo performance v realnem času kjerkoli in kadarkoli. Sisteme za spremljanje in nadzor sestavljajo pametna omrežja in pametni merilniki, ki razkrivajo operativne vzorce, ključna področja za morebitne izboljšave, napovedujejo bodoče rezultate in optimizirajo operacije ter procese, kar vodi do nižjih stroškov in višje produktivnosti. Največje inovacije na področju sistemov za spremljanje in nadzor so predstavljene v okviru »pametnega doma«, kjer je največja dodana vrednost za kupce prav zaščita in varovanje oseb ter lastnine in varčevanje z energijo.

Naprave IoT in stroji z vgrajenimi senzorji proizvajajo velike količine podatkov in jih posredujejo v orodja za poslovno analitiko z namenom, da lahko ljudje v realnem času sprejemajo odločitve glede na prejete podatke. Ti podatki se uporabljajo za odkrivanje in reševanje poslovnih problemov, kot so spremembe v vedenju kupca, spremembe pogojev na trgu ali nezadovoljstvo kupcev. Orodja za poslovno analitiko so lahko vgrajena tudi v naprave IoT, kot so na primer prenosljivi senzorji za spremljanje zdravja, kjer se odločitve izvajajo v realnem času na izvoru podatkov. Deljenje informacij in sodelovanje znotraj omrežja IoT lahko nastopi med uporabniki, med uporabnikom in napravo ter med napravami. IoT se danes največ uporablja v proizvodnji, trgovini, informacijskih storitvah ter financah in zavarovanju [16].

4.4.1 Arhitektura IoT

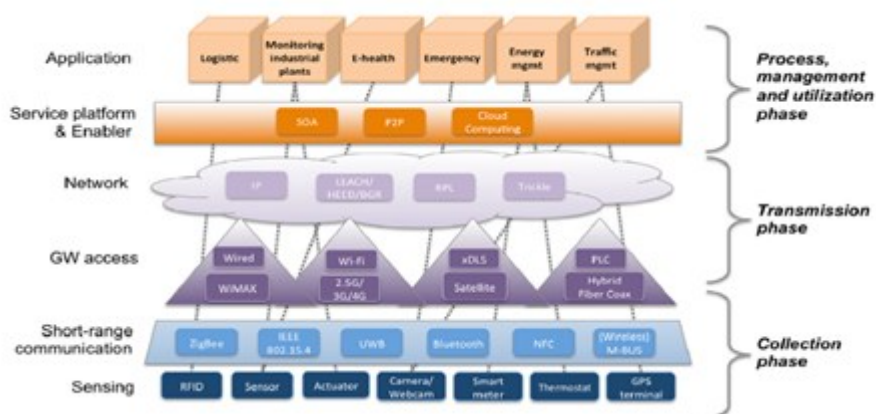
Arhitektura IoT je v grobem sestavljena iz senzorjev, mobilnega dostopa in računalništva v oblaku. Pametne naprave oblikujejo tako imenovani senzorični roj (angl. sensory swarm) in sestavljajo večino sistema. Te naprave so zelo heterogene glede na zmožnosti samih naprav, njihovo življenjsko dobo in komunikacijsko tehnologijo. Te naprave bodo po količini presegle današnje naprave, kot so pametni telefoni ali tablice, in bodo imele dostop do interneta. V samem jedru arhitekture IoT se namesto klasičnih strežnikov uporablja računalniški oblak, ki omogoča hitre računske operacije ter hrambo ogromnih količin podatkov. Del teh povezanih naprav v omrežju bo prenosnih, večina jih bo vgrajena v infrastrukturo. V tej dolgoročni viziji bodo ljudje čez nekaj let popolnoma potopljeni v svet tehnologije, kar bo vodilo do tako imenovanega »Potopljenega človeka« (angl. Immersed human) [10].



Slika 9: Arhitektura IoT [10]

V IoT imamo tri ključne faze, kjer med fizičnim in virtualnim svetom poteka neprestana interakcija:

- Faza zbiranja (angl. collection phase) se nanaša na procedure za zaznavanje fizičnega okolja, zbiranje fizičnih podatkov v realnem času in rekonstrukcijo splošnega dojemanja okolja.
- Faza prenosa (angl. transmission phase) vključuje mehanizme za dostavo zbranih podatkov do aplikacij in različnih zunanjih strežnikov ali oblaka.
- Faza procesiranja, upravljanja ter uporabe (ang. process, management and utilization phase) se ukvarja s procesiranjem in analiziranjem toka informacij, posredovanjem podatkov do aplikacij in storitev ter zagotavljanjem povratnih informacij kontrolnim aplikacijam. Ta faza je odgovorna za kritične funkcije, kot so odkrivanje naprav, upravljanje naprav, filtriranje podatkov, agregiranje podatkov, semantična analiza in uporaba informacij [10].



Slika 10: Horizontalna predstavitev aplikacij IoT [10]

IoT bo v prihodnosti zahteval zelo malo ali skoraj nič človeških posegov, zato morajo biti naprave samostojne (angl. self-/ capabilities) in nuditi:

- visoko stopnjo konfiguracijske avtonomije
- samoorganizacijo in samoprilagoditev na različne scenarije

- samostojno reakcijo na dogodke in dražljaje
- samoproceniranje velikega števila izmenjanih podatkov, ki jih lahko uporabljajo tudi tretje osebe.

IoT mora zagotavljati varno okolje vse od varovanja komunikacij, avtentikacije, integritete podatkov in naprav, zasebnosti uporabnikov do varovanja osebnih podatkov ter omogočati zanesljivost okolja in vključenih tretjih oseb [10].

Upravljanje z Big Data na področju IoT je ekstremno zahtevno zaradi različnih lastnosti podatkov, ki so zbrani iz različnih naprav in senzorjev, od katerih ima vsaka različne metode za predstavitev podatkov in semantiko. Zbrani podatki imajo pogosto različno razmerje časa in prostora (angl. time-space) za opis dinamike lokacije naprave v določenem času. V nasprotju z današnjimi aplikacijami, kjer se podatki ponavadi uporabljajo v eni aplikaciji, se bodo podatki v prihodnje delili med različnimi aplikacijami IoT, kar zahteva večjo povezljivost med njimi.

Arhiviranje podatkov je še en izziv na področju IoT. Po določenem času, ko podatki postanejo zastareli, je potrebno definirati ustrezne politike, da določimo, katere podatke obdržimo in katere ne. Neustrezne politike lahko vodijo do izgube podatkov, nepravilnega shranjevanja ali manjkajočih podatkov.

Varnost je prav tako ena od ključnih komponent sistemov IoT. Za zagotavljanje varnosti podatkov, storitev in celotnega ekosistema IoT moramo posvetiti veliko pozornosti zaupnosti, integriteti, avtentikaciji, avtorizaciji, nezatajljivosti, razpoložljivosti in zasebnosti. Štiri ključne zahteve za IoT varnost so:

- varna avtentikacija in avtorizacija
- varen zagon naprav in prenos podatkov
- varnost IoT podatkov
- varen dostop do podatkov preko avtorizirane osebe

Uporaba koncepta družbenih omrežij v kontekstu IoT lahko odpre nove možnosti za interakcijo med pametnimi napravami. Glavna ideja je v tem, da imajo lahko naprave družbeno zavest in lahko kažejo družbeno vedenje, kar jim omogoča izdelavo svojega družbenega omrežja naprav. To družbeno omrežje naprav lahko izkoristimo za krepitev zaupanja med napravami, ki postanejo »prijatelji« in tako zagotovijo večjo pretočnost omrežja z namenom, da postanejo aplikacije in storitve učinkovitejše. Obstaja več različnih stopenj družbene vključenosti naprav. Prva stopnja temelji na izkoriščanju ljudi in njihovih razmerij na družbenih omrežjih, za posredovanje in deljenje podatkov, ki jih generirajo pametne naprave. Z uporabo različnih spletnih in komunikacijskih protokolov lahko naprave komunicirajo z družbenim omrežjem uporabnika (objavijo informacijo o svojem statusu na Facebooku), vendar ne delijo informacij z drugimi napravami. V drugi stopnji imajo naprave interakcijo z okoljem in kažejo družbeno vedenje z drugimi napravami v omrežju. Naprava lahko na primer vzpostavi začasno razmerje z drugo napravo, vendar je še vedno kontrolirana s strani njenega lastnika. Zadnja stopnja so »družbene naprave«, ki tvorijo aktivno družbeno omrežje naprav. Tukaj govorimo o določenih razmerjih, ki so vzpostavljena v družbenem omrežju naprav in jo lahko kličemo tudi družbeni internet stvari SIoT (angl. Social Internet of IoT). Ta razmerja obstajajo le med napravami, ki postanejo »prijatelji« in ne med njihovimi lastniki [10].

Razvoj aplikacij IoT ima različne življenjske cikle, kot so razvoj, namestitve in vzdrževanje. V fazi razvoja se mora analizirati in razviti aplikacijsko logiko, ki jo je potrebno razdeliti v več nalog za spodnje omrežje (angl. underlying network), ki vsebuje veliko število heterogenih naprav. V fazi namestitve se mora aplikacijska logika namestiti na veliko število različnih naprav, kar lahko v praksi povzroča velike težave. V fazi vzdrževanja sistema IoT lahko pride do sprememb in nadgradenj funkcionalnosti ali dodajanja in odstranjevanja naprav. Ročno delo v vseh treh fazah za več tisoč naprav zahteva veliko truda in verjetnost, da pride do napak, je zelo velika. Za odpravo teh izzivov so se pojavili številni pristopi, kot je programiranje centralnega vozlišča (angl. node-centric programming) ali sistemi za makroprogramiranje (angl. macroprogramming) [39].

5 Uporaba personalizacije za pospeševanje prodaje

5.1 E-trgovanje in m-trgovanje

E-trgovanje in m-trgovanje sta v zadnjem desetletju doživela ogromno rast. Glede na podatke E-Marketerja je globalna prodaja v segmentu B2C v letu 2013 dosegla 1,2 biljarde \$, kar je bilo 17,1% povečanje v enem letu in bo v letu 2016 dosegla 1,8 biljarde \$. Glede na priljubljenost spletnega in mobilnega trgovanja so spletni trgovci predstavili različne tipe priporočanja produktov z namenom, da pomagajo uporabniku pri nakupni izkušnji in odločitvi. Najbolj izrazit primer priporočila v e-trgovanju je uporabniško generirano sporočilo od ust do ust (angl. word of mouth WOM), ki se na spletu pojavlja v obliki komentarjev in ocen uporabnikov. Amazon je bil eden prvih, ki je na njihovi spletni strani omogočil uporabnikom oddajo komentarja za določen produkt in je sedaj prepoznan po svojih obsežnih komentarjih za produkte. Glede na nekatere ankete kar 85 % uporabnikov pred nakupom pogleda spletne komentarje in kar 65 % uporabnikov trdi, da spletni komentarji vplivajo na njihovo nakupno odločitev [57].

5.2 1-1 marketing

Številna podjetja sprejemajo teorijo ciljanega trženja (angl. target marketing), kjer marketinški specialisti ločijo večje segmente kupcev, izberejo enega ali več ciljnih segmentov in izdelajo marketinški plan za izbrani segment. Ciljni segment sestoji iz skupine kupcev, ki imajo podobne interese ali želje. Kupčeve karakteristike so razdeljene na več segmentov, od geografskih (državljanstvo, država, regija, mesto, naselje), demografskih (starost, velikost družine, spol, prihodki, izobrazba), psihografskih (življenjski stil, osebnost, vrednote) do vedenjskih (status uporabnika, status uporabe in nakupa, lojalnost blagovne znamke) spremenljivk [29].

Ena na ena marketing se razlikuje od tradicionalnega marketinga, ki se uporablja za promocijo produktov vsem kupcem ali določeni skupini kupcev. Ena na ena marketing se fokusira na postopno razumevanje kupca in poskuša zapolniti njegove želje in potrebe s priporočilom ustreznih produktov in storitev.

Namen izvajanja 1-1 marketinga je povečati zvestobo kupcev in povečati prodajo. Paretovo pravilo pravi, da 20 % kupcev generira 80 % dobička podjetja. Personalizirani priporočilni sistemi lahko zagotovijo priporočilo 1-1 za produkte in storitve glede na kupčevo preteklo vedenje in s sklepanjem glede na druge kupce s podobnimi preferencami. Podjetja uporabljajo različne priporočilne sisteme in implementirajo nove strategije, da lahko na konkurenčnem trgu obdržijo obstoječe kupce in privabijo nove [29].

5.3 Zasebnost

Zasebnost je moralna pravica posameznika, da se ga pusti pri miru, brez nadzorovanja ali vmešavanja s strani drugih uporabnikov, podjetij ali države. Danes so podatki o vedenju uporabnikov, uporabi spletnih in mobilnih aplikacij, osebni profili in nakupne transakcije dostopne različnim vladnim organizacijam in organom pregona, kar prispeva k povečanju strahu pri uporabi spletnih in mobilnih aplikacij. V zadnjih letih se pojavlja vedno več razkritij o tem, da države rutinsko zbirajo

informacije o svojih in tujih državljanih, predvsem o njihovih klicih in uporabi interneta. Ameriške in druge varnostne agencije tesno sodelujejo z velikimi IT-podjetji, kot so Google, Facebook, Twitter, in telekomunikacijskimi podjetji, kot so Verizon, AT&T in drugi, kar vzbuja vedno več skrbi glede zasebnosti in varovanja podatkov. Napredne tehnologije za shranjevanje, procesiranje in analiziranje velikanskih količin osebnih podatkov, imenovanih tudi kot Big Data, še nadalje povečujejo percepcijo, da je zasebnost zelo težko definirati in varovati v obdobju e-trgovanja, m-trgovanja in družbenih omrežij. Ford je zapisal, da je vzpostavitev ravnotežja med varnostjo in svobodo v središču razprave o zasebnosti. V nekaterih državah, kot so ZDA, Kanada in Nemčija, je pravica do zasebnosti eksplicitno zapisana v ustavo ali pa izhaja iz ustanovnih dokumentov in zakonskih aktov.

Za varovanje zasebnosti se uporablja koncept obveščene soglasja (angl. informed consent), ki je definirano kot soglasje uporabnika, podano z znanjem o vseh pomembnih dejstvih, ki so potrebni za racionalno odločitev. V ZDA lahko podjetja in vladne agencije zbirajo podatke in transakcije pri spletnem nakupovanju in potem te podatke uporabijo za druge marketinške aktivnosti brez pridobitve soglasja uporabnika. V Evropi je to prepovedano in podjetje ne sme uporabljati podatkov o nakupnih transakcijah za noben drug namen, razen za podporo trenutnemu nakupu, razen če za to ne pridobi soglasja uporabnika, ki se strinja s politiko piškotkov in splošnimi pogoji poslovanja. V nekaterih primerih je potrebno za obdelavo podatkov pridobiti tudi pisno soglasje.

Tradicionalno obstajata dva modela obveščene soglasja, to sta opt-in in opt-out. Opt-in model zahteva potrditveno akcijo s strani uporabnika, da soglašata z zbiranjem in uporabo informacij. V nasprotnem primeru je privzeta vrednost, da se uporabnik ne strinja z zbiranjem podatkov. V opt-out modelu je privzeta vrednost, da podjetje lahko zbira podatke, razen če uporabnik ne potrdi, da ne želi, da zbirajo njegove podatke. To stori na način, da eksplicitno obkljuka vrednost v izbirnem seznamu ali izpolni določen obrazec.

Evropska komisija je leta 1988 izdala direktivo za varovanje podatkov, ki standardizira in razširja pravico do zasebnosti v EU državah. Direktiva je osnovana na doktrini pravične informacijske prakse (angl. Fair Information Practices), vendar razširja nadzor uporabnika nad uporabo in izvajanjem njegovih osebnih podatkov. Direktiva nalaga podjetjem, da informirajo uporabnike, kdaj in kje se zbirajo določeni podatki, in da transparentno razkrijejo, kako se bodo ti podatki hranili in uporabljali. Uporabniki morajo za vsako zbiranje podatkov dati obveščeno soglasje in imajo pravico do dostopa do zbranih podatkov, jih lahko tudi popravijo in zahtevajo, da se njihovih podatkov več ne zbira ali da se izbrišejo. V letu 2012 je EU objavila pomembne spremembe pri varovanju podatkov, ki se nanašajo na vsa podjetja, ki izvajajo storitve v Evropi. EU od internetnih podjetij, kot so Amazon, Facebook, Google, Apple in drugih zahteva, da pridobijo eksplicitno uporabnikovo soglasje glede uporabe njihovih osebnih podatkov, da izbrišejo vse podatke o uporabniku v primeru zahteve za izbris preko tako imenovane pravice biti pozabljen (angl. right to be forgotten) in da lahko obdržijo informacije le tako dolgo, kolikor je to nujno potrebno. Regulativa omogoča uporabnikom, da prenesejo vsa svoja besedila, fotografije in video posnetke k drugim ponudnikom storitev.

Ameriška trgovinska zbornica (angl. Federal Trade Commission FTC) je izdala ogroditve za upoštevanje zasebnosti, ki naj bi veljalo za vse komercialne ponudnike, ki zbirajo in uporabljajo uporabniške podatke. Obstajajo tri ključne smernice:

- Zasebnost v načrtovanju (angl. Privacy by Design), ki vzpodbuja podjetja in zaposlene, da promovirajo zasebnost uporabnika skozi celotno organizacijo in v vsaki fazi razvoja produktov in storitev.
- Poenostavljena izbira (angl. Simplified Choice) priporoča podjetjem, da ponudijo poenostavljeno izbiro glede odločitve za zbiranje podatkov in da morajo biti uporabniku jasno in vidno predstavljene vse informacije, in sicer v času in kontekstu, v katerem uporabnik posreduje podatke. Za nekatere posebne podatke, kot so podatki o otrocih, finančni in zdravstveni podatki, pa zahtevajo še dodatno soglasje. Priporoča se tudi posebni mehanizem za enostavno izbiro glede odločitve o zbiranju podatkov za vedenjsko oglaševanje z možnostjo izbire »Ne sledi me« (angl. Do not track).
- Večja transparentnost (angl. Greater Transparency) priporoča podjetjem povečano transparentnost pri ravnanju s podatki z izdelavo jasnejših, krajših in bolj standardiziranih splošnih pogojev poslovanja in pravilnikov o zasebnosti. S tem se omogoči boljše razumevanje in lažje primerjanje med posameznimi trgovci. Uporabniku morajo zagotoviti ustrezen dostop do njegovih podatkov in izobraževati uporabnike o poslovnih praksah glede zasebnosti podatkov [26].

Edinstven izziv za upravljanje zasebnosti predstavljajo družbena omrežja, saj vzpodbujajo uporabnike, da razkrivajo svoje osebne podatke (strast, hobiji, ljubezen, interesi, služba, zdravstveno stanje) in da jih delijo s svojimi prijatelji, družino in sodelavci. Družbena omrežja so zelo povečala globino, obseg in bogastvo informacij, ki so zbrane s strani zasebnih podjetij, zato je težko določiti, kaj je zasebno, če je vse deljeno, in kako lahko nekdo pričakuje zasebnost, če podatke javno objavlja [26].

5.4 Vedenjsko raziskovanje

Obstajata dve komponenti znanosti o znanju: to sta empirično raziskovanje in teorija. Empirično raziskovanje vključuje merjenje opazovanih dogodkov in se nanaša na informacije, ki jih občutimo, vidimo, slišimo, se jih dotaknemo, jih vohamo ali čutimo. Subjektivne lastnosti, kot so čustva in prepričanja, postanejo empirična, kadar so izražena s pomočjo lestvic, intervjujev, ocen ali katerih drugih tehnik merjenja. Teorija znanja je sistematična izjava o načelih, ki opišejo nek naravni pojav, ki ga samega po sebi ni mogoče neposredno opazovati, vendar ga je mogoče podpreti ali ovreči z empiričnimi dognanji. Teorija in empirično raziskovanje sta povezana preko hipotez, to so testni (angl. testable) predlogi, ki logično izhajajo iz teorije. Testni vidik je zelo pomemben, saj morajo znanstvene hipoteze imeti sposobnost, da se jih sprejme ali zavrže.

Vedenjska raziskava poteka v soglasju z znanstveno metodo, kjer je subjekt neposredno opazovan ali se izvaja preko kakšne druge metode, kot je odgovarjanje na anketo. Da so lahko določene raziskave znanstvene, morajo biti pridobljeni podatki veljavni (angl. valid) in zanesljivi (angl. reliable). Veljavnost je stopnja, s katero postopek proizvaja pristne in verodostojne informacije, in ima dva vidika, interno in eksterno veljavnost. Interna veljavnost je stopnja, do katere procedura meri tisto, kar bi morala meriti. Eksterna veljavnost se nanaša na posploševanje ugotovitev in definira, ali rezultati segajo preko splošnih nastavitvev ali situacij. Zanesljivost se nanaša na ponovljivost pridobljenih ugotovitev. Procedure morajo proizvesti iste rezultate, kot so uporabljene na podobnih ljudeh v podobnih situacijah ali istih ljudeh ob drugi priložnosti. Vedenjske raziskave izvajamo z namenom, da

pridobimo odgovore na zahtevana vprašanja ali pridobimo informacije o človeškem vedenju.

Za namene vedenjskega raziskovanja obstaja veliko metod. Največ se uporabljajo štiri ključne tehnike: opazovanje, eksperimentiranje, vprašalnik in intervju.

Opazovanje je zelo primerno za raziskovanje, kaj ljudje počnejo v javnosti. Za opazovanje zasebnega vedenja je najbolje uporabiti osebni dnevnik. Za pridobivanje mnenj in stališč so zelo učinkoviti vprašalniki in intervjuji. Za oceno mentalne sposobnosti se uporabljajo v večini primerov standardizirani testi.

Galton je že leta 1907 odkril, da obstajajo pomembne razlike v tem, kako ljudje razmišljajo, in odkril dodano vrednost vprašalnika kot instrumenta za raziskovanje vedenja, ki se ga ne da direktno opazovati ali eksperimentirati. Vprašalnik je niz pisnih vprašanj na določeno temo, za katero iščemo mnenje anketiranca. Pogosto se uporablja v anketnih raziskavah, kjer gre za sistematično zbiranje informacij o človeških prepričanjih, odnosih, vrednostih in vedenju.

Obstajata dva glavna vidika za izdelavo vprašalnika, vsebina in format. Vsebina se nanaša na objekt opazovanja in pri izdelavi vprašalnika se priporoča, da se usmerimo samo v eno temo. Pred izdelavo vprašalnika lahko začnemo z dvema drugima metodama, občasno opazovanje in intervju. Namen občasnega opazovanja je, da izvemo in se naučimo vrsto dejavnosti, o katerih bomo postavili vprašanja, saj moramo najprej vedeti, kaj se sploh dogaja, da lahko postavimo vprašanja o tem. Ta faza zahteva krajši pregled kot pa sistematično opazovanje s podrobnimi kategorijami. Fazo opazovanja mora spremljati intervju, da dodatno pridobimo še mnenja udeležencev s pomočjo odprtega pogovora, s čimer se izognemo, da ljudem vnaprej predlagamo odgovore. Vsebina intervjuja bo nato uporabljena za določanje tem, ki se bodo pojavile v vprašalniku. Format vprašalnika se nanaša na njegovo strukturo in videz. Obstajata dve vrsti vprašalnika, odprti (angl. open-ended) in zaprti (angl. closed). Pri odprtem vprašalniku anketiranec zapiše svoje lastne odgovore. Primer vprašanja bi bil »Kaj vam je najbolj všeč pri našem produktu?« Zaprti vprašalnik, znan kot večizbirni vprašalnik, ponudi anketirancu, da izbere med ponujenimi alternativami, ki jih je določil raziskovalec. Primer vprašanja bi bil »Kako uporaben se vam je zdel naš produkt,« pri čemer lahko anketiranec izbere med možnostmi »zelo všeč, všeč, ni mi všeč in ne morem oceniti«.

Odprti vprašalnik je bolj zaželen v primerih:

- kadar raziskovalec ne pozna vseh možnih odgovorov na vprašanje,
- kadar je število možnih odgovorov tako veliko, da bi postali neprirodni v večizbirnem formatu,
- kadar se raziskovalec želi izogniti predlaganim odgovorom,
- kadar raziskovalec želi odgovor z anketirančevimi besedami.

Večizbirni vprašalniki so primerni v primerih:

- kadar je veliko število anketirancev in vprašanj,
- kadar se bodo odgovori točkovali s pomočjo računalnika,
- kadar se bodo odgovori primerjali med skupinami.

Vprašalniki, ki uporabljajo ob odgovorih še uvrstitev (angl. Ranking) ali ocene (angl. Rating), lahko dodatno zmedejo anketirance. Prav tako jih je težje analizirati, saj nekateri izberejo le najboljše možnosti, nekateri napačno interpretirajo skalo, uporabijo 1 za najbolj pomembno možnost in 5 kot najslabšo, čeprav so navodila bila

drugačna. Večje kot je število izbir za uvrstitev in bolj kompliciran je format, več napak bo nastalo v odgovorih.

Merjenje srednjega položaja (angl. middle position), ki v meritveni skali zaseda sredino, imenujemo tudi kot nevtralna ali neodločna izbira. Velikokrat tukaj ni točno jasno, kaj je anketiranec mislil, ko je označil srednjo možnost. Včasih pomeni ravnotežje med pozitivnimi in negativnimi občutki glede določene teme, včasih pa pomanjkanje interesa ali znanja glede teme. Nekateri raziskovalci pri raziskavah odstranijo srednjo možnost in s tem zagotovijo obvezno izbiro in odločitev, kjer se anketiranec mora strinjati ali ne strinjati oziroma zavzeti kakšno drugo stališče. Z uporabo srednje možnosti lahko pri vprašalniku zmanjšamo število anketirancev, ki bodo izrazili jasno mnenje.

Število vprašanj v vprašalniku mora biti čim krajše, saj v nasprotnem primeru anketiranci postanejo utrujeni in izgubijo interes, ko se prebijajo skozi neskončno število vprašanj. Priprava vsebine za vprašanja mora biti jasna in smiselna, izrazi ne smejo biti pretežki in prav tako ne smemo podcenjevati stopnje besednjaka. Potrebno je definirati vse težke besede ali žargone in po potrebi vključiti sinonime, saj s tem lahko dosežemo ljudi, ki niso razumeli primarnega izraza. Izogibati se je potrebno dvojnemu vprašanju in negativnim fraznim vprašanjem, kot je uporaba besede »ne«. Če se že odločimo za uporabo teh besed, jih je potrebno podčrtati ali napisati poševno. Vprašanja morajo biti kulturno občutljiva, saj imajo v nekaterih drugih državah določene besede drugačen pomen in jih je potrebno prilagoditi.

Ravnovesje (angl. Balance) pri vprašalniku se nanaša na nevtralnost vprašanj in zagotavljanje ustreznega števila odgovorov, tako da so odgovori, ki se nagibljejo proti eni strani, uravnovešeni z enakim številom odgovorov, ki se nagibljejo na drugo stran. Z zagotavljanjem ravnovesja zmanjšamo efekt mogočega odziva pristranskosti in naredimo vprašalnik pravičnejši.

Pri vrstnem redu vprašanj je pomembno, da začnemo z dejanskimi in nekontraverznimi vprašanji ter s tem poskušamo vzpostaviti dober odnos z anketirancem, ki lahko olajša pot do kasnejših težjih in kontroverznih vprašanj. Pomembno je tudi, da vprašanja vzdržujemo v logičnem in razumljivem zaporedju. Rutinska vprašanja, kot so starost in spol, se lahko dodajo na koncu. Vprašalnik se ne sme začeti z osebnimi in občutljivimi vprašanji, kot so nezakonite dejavnosti, spolnost, boleznin ali občutljiva verska in politična vprašanja.

Ko vprašalnik izdelamo, ga pretestiramo na manjšem vzorcu uporabnikov in po potrebi popravimo. Nato ga distribuiramo do vseh anketirancev in pridobimo odgovore na vprašalnik, ki pa jih je potrebno pravilno interpretirati. Glavni namen raziskave ni odkriti le napak in frustracij uporabnikov, ampak lahko preko raziskave identificiramo zadovoljstvo. Pri predstavitvi rezultatov ni nujno, da je sekvenca vprašanj enaka, kot je bila na vprašalniku. Bolje je, da rezultate predstavimo po temah, kjer začnemo z najbolj pomembno. Prav tako je pomembno, da v predstavitvi ni ogromno statistik in da je podrobno opisano vsako pomembno dejstvo. Telo poročila naj vsebuje le ključne ugotovitve in prav tako je za pričakovati, da bodo nekateri prebrali samo povzetek, zato naj bodo ključne ugotovitve na preprost in razumljiv način predstavljene tudi v povzetku. Pomembno je, da so aktualni podatki na voljo tudi za tiste, ki to želijo, zato naj bodo podrobnosti z vsemi podatki predstavljene v dodatku, kjer ne bodo prekinile pretoka poročila. Surove podatke shranimo na računalnik in naredimo rezervno kopijo, originalne vprašalnike na papirju pa hranimo še nekaj mesecev po raziskavi, če bi se slučajno pojavila še kakšna dodatna vprašanja, nato jih lahko recikliramo.

Internetne ali mobilne raziskave lahko izvajamo preko spletnih strani ali mobilnih aplikacij, kjer enostavno pošljemo URL-naslov raziskave po e-pošti ali preko kakšnega drugega komunikacijskega kanala. Internetni vprašalniki so postali v zadnjem času zelo priljubljeni, predvsem zaradi nizkih stroškov in hitrosti. Vprašalnik je prav tako veliko bolj interaktiven kot na papirju, poleg tega je mogoče izvajati spremljevalna (angl. follow up) vprašanja, prilagojena specifičnim odgovorom. Če na primer izberemo odgovor A, nas bo pripeljalo do naslednjega spremljevalnega vprašanja, ki je drugačno, kot če bi izbrali alternativni odgovor B ali C. Največja prednost je, da so rezultati v elektronski obliki in jih je zelo enostavno obdelovati v raznoraznih statističnih programih. Glavne omejitve spletnega vprašalnika so v tem, da ni primeren za anketirance, ki so zelo mladi ali stari, bolni ali nezainteresirani za to temo. Prav tako ni primeren za ljudi, ki so na poti ali zelo zaposleni s svojimi aktivnostmi. Vprašalniki se veliko anketirancem zdijo brezosebni, mehanični in ponižujoči, tudi predlagani odgovori se jim velikokrat zdijo omejeni in umetni. Vprašalniki prav tako niso primeri za poglobljene raziskave glede motivacije ali mnenj o določenih kompleksnih temah [44].

5.5 Personalizacija

E-trgovanje s pomočjo usmerjenega marketinga 1:1 omogoča množične prilagoditve (angl. mass customization) produktov in storitev. To bo postal primarni način proizvodnje v naslednjih desetletjih in naprej. Lastnosti e-trgovanja omogočajo vključevanje kupcev v procese načrtovanja in proizvodnje, kar omogoča proizvajalcem in ponudnikom produktov neposredno interakcijo s svojimi kupci in na ta način lahko zajamejo njihove zahteve in želje. V zadnjih letih se je pojavilo veliko število spletnih trgovin, ki omogočajo prilagoditve produktov, kot je na primer Dell.com. Ti sistemi omogočajo proizvajalcem, da se odzovejo na številne različne zahteve in naročila svojih kupcev ter lahko s prilagajanjem ponudbe že vnaprej predvidijo zahteve in želje svojih kupcev, kar imenujemo personalizacija. Spletne trgovine, ki omogočajo nešteto možnosti, pogosto naletijo na težave pri podpori kupcem ob iskanju njihovega dragocenega produkta, ki mora ustrezati heterogenim potrebam. Kupci se soočajo s problemom nasičenja ponudbe in podatkov, sprejemati morajo kompromise med velikim številom konkurenčnih produktov, soočajo se s pomanjkanjem profesionalnega znanja, ki je zahtevano za oceno produkta in primerjavo performančnosti produkta. Za reševanje teh problemov se uporablja različne priporočilne tehnike, ki pa zahtevajo, da kupci izrazijo svoje zahteve in mnenja. Zaradi slabosti nekaterih tradicionalnih pristopov se priporoča, da za svetovanje in priporočanje pridobimo čim natančnejše posameznikove zahteve. Ker so te zahteve lahko zelo heterogene, se priporoča odprto okolje, ki kupcu omogoča, da izrazi svoje raznolike zahteve v celoti in na svoj način. Če se želimo izogniti težavam pri ocenjevanju preferenc, se priporoča, da se vzpostavijo nekateri modeli, ki omogočajo direktno napovedovanje produktov glede na zahteve stranke. Pri vzpostavitvi priporočilnih sistemov za personalizacijo v e-trgovanju B2C se pojavljajo določene težave, saj kupci uporabljajo svoj lastni naravni jezik, da izrazijo svoje želje in potrebe. Njihove zahteve so ponavadi kvalitativne, nenatančne in dvomljive predvsem zaradi jezikovnih barrier. Uporabljajo se sinonimi za podobne ali iste zahteve. Prav tako so v večini primerov dodane številne besede, ki ne prispevajo ničesar k pridobivanju informacij, kar povzroča težave pri razumevanju kupčevih zahtev. Prav tako je zahtevno identificirati povezave med objekti in njihovimi nazivi razredov (angl. class label). Danes imamo razvite številne metode, kot so odločitvena

drevesa in regresijski modeli, ki so razviti z namenom, da identificirajo povezave med objekti in njihovimi razredi, vendar so te metode primerne le za klasifikacijo strukturiranih podatkov, to pomeni, da so podatki objekta organizirani glede na fiksno skupino atributov ali dimenzij. Zato splošno uporabljana relacijsko podatkovno orientirana klasifikacija ne more biti uporabljena za klasifikacijo kupčevih zahtev, ki so organizirane kot skupina tekstovnih dokumentov. Zaradi teh težav se pri načrtovanju priporočilnih sistemov za personalizacijo zahteve uporabnikov procesirajo s pomočjo semantične analize in so predstavljene kot tekstovni dokumenti [51].

Personalizacija podjetju prinaša strateško orodje za diferenciacijo produktov in storitev, še posebej v primeru, če je na trgu huda konkurenca. Zaradi izboljšanja prodaje in uporabniške izkušnje so podjetja sprejela različne strategije personalizacije za pridobitev in zadržanje svojih kupcev.

Zaradi svojih interdisciplinarnih karakteristik so personalizacijo preučevali na številnih akademskih področjih od ekonomike, upravljanja, marketinga, informacijskih sistemov do računalništva. To je omogočilo razvoj številnih strategij personalizacije, ki se razlikujejo v svojih elementih, kdo je subjekt (kdo izvaja personalizacijo) in objekt (kaj je personalizirano) personalizacije. Računalniške študije so raziskovale vpliv različnih strategij personalizacije z uporabo metrik natančnosti, kot je ocena razlike med aktualno in napovedano vrednostjo. Ker te metrike ne morejo zajeti bolj zapletenih in subtilnih vidikov personalizacije, se razvijajo splošnejši vidiki uspešnosti personalizacije z zavzemanjem za obsežnejše meritve, kot so življenjska doba kupca, zvestoba, nakupovalna izkušnja in donosnost stranke. Glede na temeljni cilj personalizacije, da povečamo zadržanje stranke (angl. customer retention), se morajo strategije in tehnologije primerjati v kontekstu zadrževanja kupca in ne v kontekstu metrik natančnosti.

Kvon in Kim predlagata štiri dimenzije za implementacijo personalizacije:

- Kaj je personalizirano (objekt personalizacije) – imamo tri plasti personalizacije produktov in storitev. Spletna stran ima lahko personalizirano vsebino, vmesnike ali strukturo; komunikacijski kanal lahko personalizira in organizira način komunikacije; cena se lahko personalizira s spremembo cene v točno določenih urnikih ali terminih (angl. pricing schedules) oziroma preko strategije diskriminacije cen.
- Kako daleč personaliziramo (stopnja personalizacije) – stopnja personalizacije je lahko ena za vse (standardizirano in ni personalizirano), ena na N (mikro segmentacija, tržni segment) ali ena na ena.
- Kdo izvaja personalizacijo (subjekt personalizacije) – personalizacija je lahko začeta s strani uporabnika ali pa sistemsko s strani podjetja. Ta dimenzija je povezana s strankinim zaznavanjem kvalitete in zadovoljstva glede personaliziranih ponudb in se jo mora upoštevati kot pomemben vidik implementacije personalizacije.
- Kako se naučiti kupčeve preference (metoda učenja preferenc) – se nanaša na metode učenja preferenc za personalizacijo.

Študije o indeksu zadovoljstva kupcev, kot sta ameriški (ACSI) in evropski (ECSI) indeks zadovoljstva, so pokazale, da izkušnja s personalizacijo in prilagoditvijo rezultira s kupčevim zadovoljstvom, ki je ključni faktor kupčeve zvestobe. Pomembnost personalizacije je danes zelo prepoznana in pojavila so se številna nova orodja in upravljavski pristopi, ki omogočajo ponudnikom, da boljše služijo svojim kupcem in zadovoljijo njihove potrebe in želje. Temeljni cilj personalizacije je

povečanje stopnje zadržanja kupca z zagotavljanjem konkurenčne dodane vrednosti. Vendar fenomen zadržanja kupcev, ki kaže na to, ali kupec še zmeraj posluje s ponudnikom storitev in ponavljajoče kupuje iste produkte, zajema neko stopnjo nejasnosti, saj predstavlja teoretični konstrukt, ki ga ne moremo opazovati direktno. Za zadrževanje strank se pojavljata dva ključna efekta, in sicer zadovoljstvo in zvestoba, ki sta močna napovedovalca zadrževanja stranke. Kupčeva zvestoba je definirana kot namen ali nagnjenje kupca, da ponovno kupuje pri istem podjetju ali da kupuje isto blagovno znamko. Na področju e-trgovanja je zvestoba kupcev bila prepoznana kot ključna pot za profitabilnost. Zadovoljstvo stranke se nanaša na skupno oceno in evalvacijo uporabniške izkušnje nakupa in uporabe produkta. Zadovoljstvo predstavlja pomembno komponento za ponavljajoče nakupe, pozitivne širitve od ust do ust (angl. word of mouth) in zvestobe. Zadovoljni kupci se vračajo in kupujejo več ter o svoji izkušnji pripovedujejo drugim prijateljem in družinskim članom, kar vodi do boljše konkurenčne prednosti, k večjemu tržnemu deležu in povečanju dobička.

Kot sta Kvon in Kim dokazala v študiji, se na področju personalizacije najbolj priporoča kombinacija personalizacije vsebine in vmesnika, kar vodi do povečanja zvestobe in zadovoljstva [28].

Zelo pomemben faktor personalizacije je danes lokacija. Mobilno trgovanje je postalo vseprisotno in podjetja lahko vzpostavijo komunikacijo s kupci kjerkoli in kadarkoli. Najpogosteje se uporabljajo mobilna tekstovna sporočila, mobilne spletne strani, mobilne aplikacije in mobilni video kanali. Uporaba mobilnih sporočil za promocijo produktov in storitev se je v zadnjih letih zelo povečala v EU in Aziji. V procesu personalizacije podjetja pridobijo kupčeve potrebe in želje, prav tako pa lahko pridobijo njihovo lokacijo in jim pošljejo prilagojena promocijska sporočila, kadar se uporabnik nahaja v bližini njihove trgovine.

Predhodne raziskave glede spletne personalizacije so se fokusirale predvsem na vsebino, vmesnike in čas, vendar so zanemarjale lokacijo, saj so uporabniki večinoma bili statični. Pri mobilni personalizaciji je lokacija ključni faktor [49].

Lokacijsko zavedajoče storitve (angl. Location aware services LAS) in lokacijsko osnovane storitve (angl. Location based services LBS) integrirajo tehnologijo geografskih informacijskih sistemov (GIS), globalnih sistemov za določanje položaja, multifunkcijskih mobilnih naprav in internetnega omrežja.

Pri izdelavi aplikacij LAS so ponavadi zahtevane štiri naloge pri modeliranju:

- kontekstualno modeliranje in prilagajanje se nanašata na informacijski tok definiranega konteksta na primer znotraj posamezne časovne cone.
- lokacijsko modeliranje specificira kontekst lokacije, kot je na primer cona z radiusom enega kilometra, ki določa, kdaj bo storitev dostavljena.
- uporabniško modeliranje – pri uporabniškem modeliranju se razvije širok nabor uporabniških lastnosti in nastavitev, kot so trenutni status uporabnika, interesni in nakupni profil uporabnika ...
- geoprostorsko modeliranje in procesiranje upravljata ter procesirata prostorske podatke in informacije, ki so jedrnato dostavljene uporabnikom.

Ena od ključnih dilem pri uporabi mobilnih aplikacij LAS je lokacijska zasebnost, ki predstavlja precejšno oviro za sprejetje aplikacije s strani uporabnikov. Te ovire glede zasebnosti lahko kompenziramo z uporabo lokacijske personalizacije.

Bose in Chen sta ugotovila, da je razumevanje uporabnikovih preferenc ob upoštevanju ciljne lokacije ključ za uspeh situacijsko kontekstualne aplikacije v okolju mobilnega marketinga. Za identifikacijo uporabnikovih preferenc lahko uporabimo različne situacijske parametre, kot so lokacija, sezona, oddaljenost, vreme, čas, starost in spol. Število situacijskih parametrov pomembno vpliva na natančnost rezultata priporočilnega sistema [6].

Sistemi za personalizacijo zahtevajo in vzdržujejo informacije o uporabnikih, kar so lahko demografski podatki, interesi, preference in zgodovinski podatki. Eden od glavnih izzivov teh sistemov je, da uporabnikovi interesi, preference, potrebe in želje niso fiksirane, ampak se spreminjajo čez čas. Če bi uporabniški profili vsebovali samo statične informacije, bi to sčasoma omejevalo personalizacijo in priporočilni sistemi bi priporočali nepomembne produkte in storitve. Za reševanje tega problema moramo uporabiti metode za razumevanje in učenje različnih vedenj uporabnika in na podlagi tega ustrezno prilagoditi profile. V večini primerov se za zajem uporabniških interesov in zagotavljanjem priporočil na podlagi teh interesov uporablja ontologija. Sistemi za personalizacijo se lahko zanašajo na različne baze znanja za učenje in modeliranje uporabniških profilov od taksonomije, podatkovnih baz do ontologije.

Hawalah in Fasli sta opisala lastnosti priporočilnega sistema za personalizacijo:

- uporabniki niso pripravljeni zagotavljati informacij o svojih interesih ali preferencah eksplicitno skozi izpolnjevanje vprašalnikov, zato mora fleksibilni personalizirani sistem poskušati zajeti interese skozi implicitno sledenje uporabnikovega vedenja, vendar čim bolj natančno.
- uporabniški interesi in želje morajo biti zajete in shranjene v primernem formatu, ki bo omogočil nadaljnje procesiranje in izвлеčenje uporabnih informacij. Z uporabo ontologije lahko dosežemo pomembno izboljšanje performanc priporočilnega sistema.
- uporabniški interesi so redko statični in se spreminjajo glede na čas, zato je potreben holistični pogled na uporabnikovo vedenje.
- uporabniški interesi so lahko kratkoročni, torej njegovi trenutni interesi, ki so zelo spremenljivi, ter dolgoročni, ki so stabilnejši skozi čas. Takšno razlikovanje interesov zajema še dodatno dimenzijo v poskušanju razumevanja uporabniških želja in potreb.
- personalizacija je ponavadi uporabljena za reševanje specifičnih domenskih problemov.

Vrednotenje priporočilnih sistemov za personalizacijo je lahko zelo težko in drago. Ker imajo ti sistemi različne namene in so zelo kompleksni, lahko strategije za evalvacijo razdelimo v tri kategorije:

- Offline vrednotenje – pri tem vrednotenju uporabimo obstoječe podatkovne ali umetne baze, kot je javna podatkovna baza MovieLens. Uporaba teh podatkovnih baz zmanjša stroške ter olajša ponovno uporabo in primerjanje rezultatov z drugimi priporočilnimi sistemi.
- Uporabniško vrednotenje – pri tem vrednotenju uporabimo realne uporabnike za testiranje performanc priporočilnega sistema. Ta način je zelo drag in je limitiran v obsegu, saj je časovno potraten pri večjem številu testnih uporabnikov. Vendar pa lahko uporabniško testiranje prinese boljše podatke glede učinkovitosti in natančnosti priporočilnih sistemov, saj so testirani v

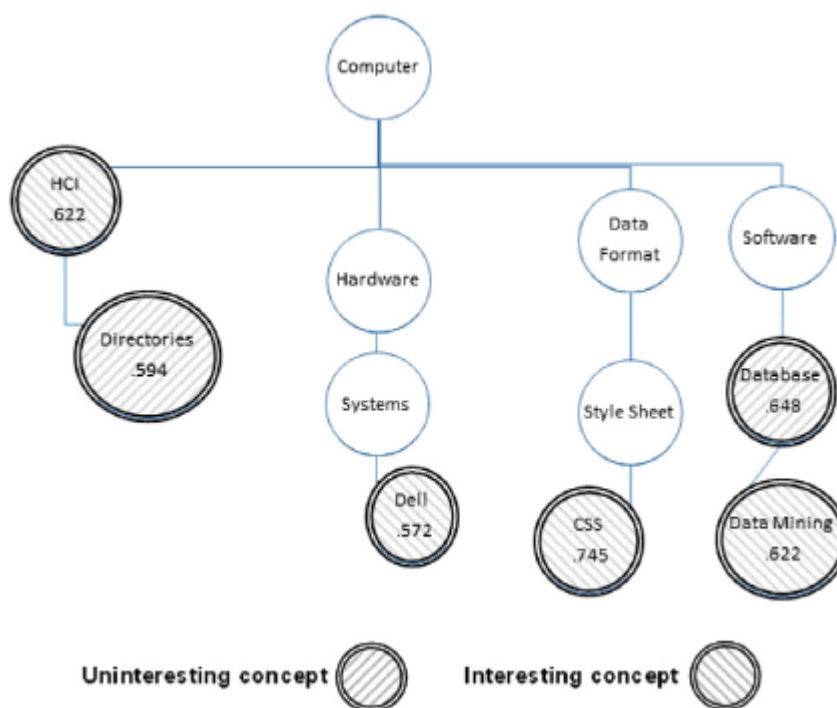
realnem okolju. Prav tako pa lahko zagotovijo odgovore na številna vprašanja uporabnikov.

- Online vrednotenje – tukaj je priporočilni sistem implementiran in vrednoten v realnem okolju. To je najboljši način za vrednotenje priporočilnih sistemov, saj testiramo vedenje uporabnikov v realnem okolju. Vendar ima ta način številne izzive, saj je potrebno sistem najprej razviti do konca, da je na voljo realnim uporabnikom, kar povzroča dodatne stroške. Prav tako ima lahko testni algoritem slabše performance, kar privede do slabše uporabniške izkušnje in izgube uporabnikovega zaupanja [2].

Noar je izpostavil, da je zelo težko identificirati, katera sestavina sporočila vodi do priljubljenegega efekta personalizacije, saj obstaja veliko pristopov personalizacije, ki se uporabljajo v številnih scenarijih. V personalizirano sporočilo lahko vključimo prejemnikovo ime, prilagojene novice, zaposlitvene priložnosti, življenjske navade; ker je toliko različnih atributov, se včasih zdi zmedeno, kaj deluje in kaj ne. V praksi se lahko zgodi, da imajo pri personaliziranih sporočilih nekateri uporabniki percepcijo, da je sporočilo bilo personalizirano, medtem ko pri drugih to ne drži. Zgodi se lahko, da uporabnik zazna nepersonalizirano sporočilo kot personalizirano oziroma da zazna personalizirano sporočilo kot nepersonalizirano.

O personalizaciji lahko govorimo kot o aktualni personalizaciji (angl. actual personalization) in zaznavni (angl. perceived personalization) personalizaciji. Aktualna personalizacija se zgodi, kadar pošiljatelj namenoma spremeni generično sporočilo glede na prej pridobljene podatke o prejemniku in mu takšno sporočilo dostavi, medtem ko je zaznavna personalizacija odvisna od tega, ali je uporabnik določeno sporočilo zaznal kot sporočilo, ki ustreza njegovim interesom in željam. Li je dokazal, da se ugodni učinek (angl. favorable effect) personalizacije pojavi, kadar ljudje zaznajo sporočilo kot personalizirano ne glede na to, ali je dejansko bilo personalizirano ali ne. Zato je potrebno teste glede učinkov personalizacije meriti glede na zaznavno personalizacijo in ne na aktualno personalizacijo. Da ljudje lahko izrazijo zadovoljstvo s personalizacijo, morajo natančno vedeti, kaj želijo, in artikulirati svoje preference pošiljatelju sporočila na jasn način. Vendar to v praksi vedno ne zdrži, saj ljudje v veliko situacijah pri sprejemanju odločitev nimajo natančno definiranih preferenc ali jih sploh nimajo [7].

Kadar je uporabnik izpostavljen personaliziranemu sporočilu, se pričakuje, da bo temu sporočilu namenil več pozornosti, ga bo skrbneje pregledal in ga verjetno uporabil pri sprejemanju odločitve.



Slika 11: Ontologija uporabniškega profila z uporabniškimi interesi [2]

Lokacijske marketinške storitve lahko uporabniku po eni strani prinašajo dodano vrednost s prejemanjem prilagojenih in personaliziranih sporočil, kar spodbudi njegove napovedane nakupe, vendar so po drugi strani veliki pomisleki o zasebnosti in razkritju osebnih informacij. To nasprotovanje med personalizacijo in zasebnostjo imenujemo paradoks zasebnosti (angl. privacy paradox), kjer uporabnik posreduje svoje osebne podatke z osebnimi pričakovanji, da bo ponudnik personaliziral sporočila in ponudbe glede na njegov profil ter bo zaupal ponudniku, da ta ne bo namerno delil njegovih osebnih informacij.

Da lahko izdelamo personalizirane ponudbe, ki so prikrojene kontekstu aktivnosti mobilnega uporabnika, lokacijske marketinške storitve zagotavljajo dostavo sporočila preko komunikacijskih in geolokacijskih sistemov, in sicer na dva načina: prikriti (angl. covert based) in odkriti (angl. overt based) pristop. Pri prikritem ali potisnjem (angl. pushed) pristopu se lokacijsko občutljiva vsebina avtomatsko pošlje uporabniku glede na prikrito opazovanje njegovega vedenja skozi sledenje fizični lokaciji njegove mobilne naprave. Pri odkritem ali povlečenem (angl. pulled) pristopu pa uporabnik zahteva informacijo in glede na njegovo lokacijo mu ponudnik posreduje personalizirano ponudbo.

Informacijska zasebnost je splošno definirana kot zmožnost posameznika, da kontrolira pogoje, pod katerimi so osebne informacije pridobljene in uporabljene. Personalizirane storitve imajo pomembne posledice na zasebnost zaradi ogromne količine zbranih osebnih podatkov za izvedbo personalizacije. V lokacijskih storitvah geografske lokacijske informacije pogosto razkrijejo položaj uporabnika v realnem času, kar omogoča potencialni vdor v zasebnost. Nepravilno ravnanje z uporabniškimi lokacijskimi podatki in drugimi osebnimi informacijami lahko vodi do razkritja vedenja in do sledenja uporabniku, kar se lahko uporabi za nezaželeni marketing, spam, cenovno diskriminacijo, nepooblaščen dostop ali kriminalno dejanje [14].

Personalizacija skozi dinamične cene je še eden od ključnih faktorjev, ki lahko vpliva na spletno prodajo. Dinamične cene (angl. Dynamic pricing) oziroma optimizacija cen je koncept ponudbe produktov po različnih cenah, ki se spreminjajo glede na povpraševanje kupcev. Oblikovanje cen blaga je odvisno od cen konkurentov, dobavne verige, povpraševanja, konverzij in prodajnih ciljev. Dinamično oblikovanje cen je široko razširjen fenomen, katerega vpliv se lahko vidi v trgovinski industriji, avtomobilski industriji, telekomunikacijah, letalskih kartah in mnogo drugih industrijah. Magloff je predlagal pet strategij dinamičnega oblikovanja cen:

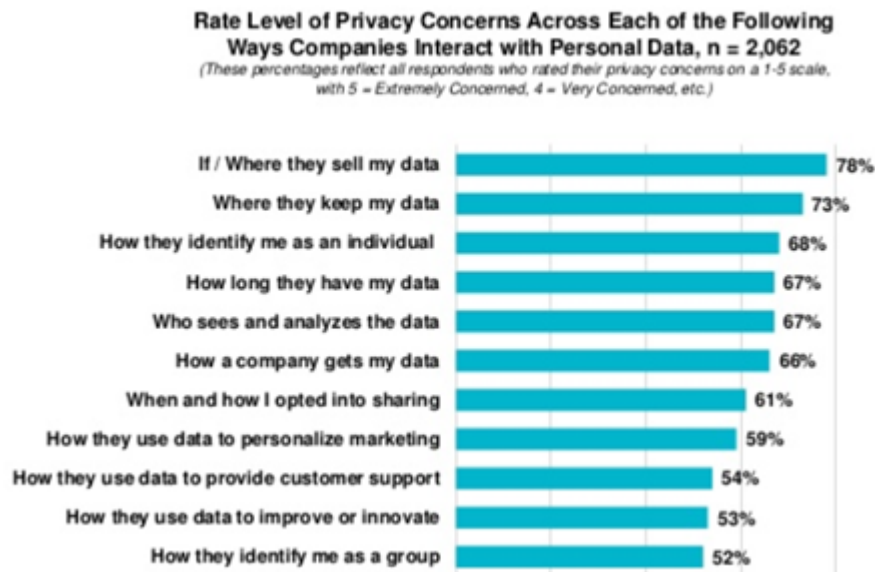
- segmentirane cene (angl. Segmented Pricing) – vključuje spremembo cen produktov glede na pripravljenost skupine, da plača to ceno.
- vrhunec nakupov (angl. Peak Use pricing) – ta strategija se veliko uporablja v transportni industriji, kjer se kupcu zaračuna dražje ob prometnih špicah ali zelo prometnih urah.
- čas storitve (angl. Service Time Pricing) – ta strategija se uporablja za obračunavanje višje cene za krajše časovne izvedbe storitve.
- cena glede na čas nakupa (angl. Time of Purchase Pricing) – ta strategija se uporablja v času nakupa, glede na pogoje ob določenem času in kraju.
- sprememba pogojev (angl. Changing Conditions Pricing) – ta strategija se uporablja v primeru velike negotovosti na trgu.

Dinamične cene postajajo vedno pomembnejši del e-trgovske industrije. Številna podjetja vpeljujejo strategijo personaliziranega spreminjanja cen zaradi pridobivanja in zadržanja svojih kupcev. Danes se uporabljajo številni modeli za določanje dinamičnih cen. Nekateri se uporabljajo za določanje cen produktov, medtem ko se drugi uporabljajo za določanje nekaterih stroškov. Poznamo metode:

- modeliranje agentov (angl. Agent Based Modeling)
- modeliranje zalog (angl. Inventory Based Modeling)
- modeliranje podatkov (angl. Data driven model)
- model teorije iger (angl. Game Theory Model)
- model strojnega učenja (angl. Machine Learning Model)
- simulacijski model (angl. Simulation Model)
- dražbeni model (angl. Auction Based Model) [42]

Personalizacija se danes izvaja tudi na družbenih omrežjih, saj uporabnik ponavadi dobi na stotine ali tisoče tvitov in objav vsak dan od svojih prijateljev, družinskih članov, podjetij ali drugih uporabnikov. Ker je teh objav veliko in se dogajajo v realnem času, bi te zadnje objave zasedle top pozicijo na domači strani in številni tviti bi bili spregledani, vključno s tistimi, za katere je uporabnik zainteresiran. Zato so personalizirana priporočila zelo pomembna v družbenih omrežjih, saj lahko pomagajo uporabniku, da ne spregleda pomembnih informacij, izboljšajo učinkovitost pridobivanja informacij, pomagajo pridobiti celovito razumevanje za posamezno temo in izboljšajo zvestobo uporabnikov. Pri personalizaciji na družbenih omrežjih je zelo pomembna priljubljenost posameznega tvita in avtoriteta uporabnika, ki je objavil tvite. Za določitev priljubljenosti posameznega tvita in avtoritete uporabnika obstajajo različni indeksi, kot so število tistih, ki jim avtor sledi, število sledilcev, število všečkov, deljenj, avtentikacije in komentarjev. Pri personalizaciji moramo upoštevati tako vpliv uporabnika kot priljubljenost vsebine, saj uporabnik med brskanjem po zanj zanimivih vsebinah upa, da bo videl pomembne, celovite in odobrene vsebine. Personalizirana blog priporočila omogočajo uporabniku, da pridobi celovito znanje o določeni temi ali dogodku ter

zmanjša negativen vpliv uporabnika, povzročen zaradi informacijske asimetrije, kar vodi do socialne stabilnosti [54].



Slika 12: Stopnja zaskrbljenosti uporabnikov glede zasebnosti in upravljanja z osebniimi podatki [2]

6 Razvoj priporočilnega in odločitvenega sistema ter mobilne aplikacije za personalizacijo prodaje QuickA

Zaradi vse večje informacijske zasičenosti in želje po boljši uporabniški izkušnji, učinkovitejšem marketingu, prodaji ter podpori strankam, podjetja vedno bolj izkoriščajo prednosti, ki jih prinašajo priporočilni in odločitveni sistemi, Big Data, napredna analitika in poslovna analitika. Podjetja lahko te sisteme integrirajo v svoje poslovanje in informacijsko infrastrukturo ali jih uporabljajo kot samostojne produkte. Z uporabo priporočilnih in odločitvenih sistemov lahko uporabniku ponudimo personalizirana marketinška in prodajna sporočila, prilagojene produkte ter storitve in na ta način povečujemo prodajo.

Raziskava podjetja Infosys je pokazala, da 96 % trgovcev na drobno meni, da personalizacija vpliva na odločitev stranke o nakupu. PayPalova raziskava je pokazala, da bo v letu 2016 mobilno nakupovanje preseglo 290 milijard dolarjev in da je v ZDA 64 % uporabnikov že uporabilo mobilno aplikacijo za nakupovanje. Emarketerjeva raziskava je pokazala, da je bila porast uporabe mobilnih aplikacij za nakupovanje, ki v večini primerov uporabljajo personalizacijo, v letu 2014 kar 174%. Trendi na področju e-trgovanja gredo v smer družbenega, mobilnega in lokalnega e-trgovanja ter personalizacije produktov in storitev s pomočjo podatkov Big Data. (eMarketer.com)

Pri raziskovanju literature s področja personalizacije in priporočilnih sistemov ter dolgoletnih izkušenj na področju razvoja informacijskih sistemov za e-trgovanje in m-trgovanje za največje slovenske trgovce sem ugotovil, da je največja težava, s katero se podjetja soočajo pri personalizaciji, pomanjkanje podatkov o kupcih. Če pa podjetja te podatke že imajo, so v veliko primerih pomanjkljivi, slabi, netočni in shranjeni po različnih informacijskih sistemih ali oddelkih. Podjetja se prav tako soočajo s problemom pridobivanja informacij glede izkušenj s preteklimi nakupi in s pomanjkanjem informacij glede prihodnjih nakupov, želja in potreb strank in zato nimajo vseh odgovorov na pomembna vprašanja, ki se tičejo marketinga, prodaje in poslovanja podjetja. Vsako uspešno podjetje, ki želi danes rasti na lokalnem ali globalnem trgu ter se razvijati, išče načine in rešitve, kako pridobiti nove kupce in kako pospeševati in povečevati prodajo svojih produktov in storitev tistim obstoječim kupcem, ki jih ti produkti zanimajo oziroma se še ne zavedajo, da jih bodo ti produkti zanimali.

Kupci se na drugi strani soočajo s problemom, da nimajo enostavne možnosti za zasebno in anonimno komunikacijo s podjetjem in blagovno znamko, preko katere bi v realnem času lahko izrazili svoja občutja, mnenja ter posredovali izkušnje glede preteklih nakupov ali pa izrazili želje po bodočih potrebah, željah in nakupih, kjerkoli in kadarkoli. Kupci trenutno na spletu puščajo digitalne sledi po raznih portalih, trgovinah, družbenih omrežjih, vendar od izbranega ponudnika ne dobijo personaliziranih produktov in storitev, kadar jih želijo in potrebujejo.

Zato sem za reševanje tega problema razvil priporočilni in odločitveni sistem za personalizacijo prodaje, imenovan QuickA, in ga preko svojega podjetja lansiral na slovenski trg. QuickA omogoča personalizirano nakupovanje, kjer kupci v interakciji z blagovno znamko posredujejo svoje preference, želje, potrebe, bodoče nakupe, pretekle izkušnje in v zameno prejmejo ugodnosti kjerkoli in kadarkoli in na ta način prihranijo denar in čas.

Podjetja s to informacijsko rešitvijo pridobijo visokopersonalizirani, zasebni marketinški in prodajni kanal, ki preko pametnih podatkov, priporočilnih in

odločitvenih sistemov ter poslovne analitike omogoča od tri- do petkrat boljše segmentacijo in targetirano pospeševanje prodaje kot Google in Facebook. Ob personaliziranem pospeševanju prodaje v realnem času omogoča izvajanje raziskav trga in kupcev ter s tem možnost pridobivanja kvalitetnih in pametnih podatkov o svojih kupcih. QuickA je bila kot informacijska rešitev sprejeta kot top inovacija na Forum inovacij s strani SPIRITA, časnik Finance jo je uvrstil med Najpodjetniške ideje, poleg tega pa je bila predstavljena na 60. marketinškem fokusu o digitalni prihodnosti preko Društva za marketing Slovenija.

Način, kako ljudje kupujejo artikle ali storitve, se je v zadnjih 10 letih dramatično spremenil, vendar prava evolucija nakupovanja z novimi orodji in digitalnimi storitvami šele prihaja. Usmerjenost v posameznega kupca, ustvarjanje dodane vrednosti, personalizacija nakupov ter inovativni pristopi v logistiki bodo v naslednjih letih prinesli velike spremembe v nakupnem procesu. Za podjetja bo ključno, da razumejo potrebe, želje in pričakovanja svojih strank, jih informirajo, zabavajo in izobražujejo glede svojih produktov in storitev ter ob tem nudijo kvalitetno podporo strankam. Večino podjetij za povečanje prodaje, izboljšanje poslovanja ter uporabniške izkušnje danes naroča zunanje raziskave, ki pa so drage, dolgotrajne in ne ponujajo odgovorov v realnem času. Naša inovativna rešitev rešuje te probleme z združevanjem procesov pospeševanja prodaje in izvedbe raziskav z namenom ponuditi kupcu boljše nakupovalno izkušnjo v celotnem nakupovalnem procesu ter mu ponuditi personalizirane produkte in storitve po ugodnejših cenah. Podjetje lahko tako v realnem času meri zadovoljstvo strank, zvestobo in predanost blagovni znamki, meri učinkovitost oglaševalskih akcij v drugih medijih, preusmeri oglaševalsko akcijo iz drugih medijev (TV, časopis ...) na mobilno aplikacijo, kjer uporabnik prevzame kupon, preverja kvaliteto svojih produktov in storitev ter pospešuje in povečuje prodajo.

Za kupca na drugi strani je najpomembnejše, da ima kjerkoli in kadarkoli veliko izbiro kvalitetnih produktov in storitev po ugodnih cenah ter da se vzpostavi dolgoročno zaupanje in zvestoba do podjetja ali blagovne znamke. Trenutno kupci preko različnih digitalnih marketinških kampanj od ponudnika dobivajo promocijska sporočila, ki za njih nimajo nobenega pomena ali jih trenutno ne potrebujejo. Z našo personalizirano rešitvijo bomo kupcem ponujali le tiste produkte in storitve, ki jih zanimajo ter jih trenutno iščejo in potrebujejo.

S Quicko lahko uporabnik preko mobilne aplikacije ali spletne strani:

1. izbere blagovno znamko ali podjetje
2. sodeluje z blagovno znamko ali podjetjem s hitrim odgovorom ali akcijo
3. prejme nagrado, akcijsko ponudbo ali program zvestobe

Uporabnik v drugem koraku sodeluje z blagovno znamko ali podjetjem in posreduje informacije skozi različne interaktivne module: ankete, promocijska sporočila, galerije, ogledi videa, prenosi slike ali videa, kvize, primerjave in ocene produkta.

Zaradi pridobivanja velikih količin osebnih in občutljivih podatkov je zasebnost za uporabnike pri Quicki ključnega pomena. Uporabniki imajo popolno kontrolo nad svojimi podatki in lahko uporabljajo aplikacijo tudi anonimno. Vsak uporabnik komunicira s posamezno blagovno znamko v svojem zasebnem kanalu in svojih odgovorov ne deli z ostalimi podjetji. Skupne odgovore in podatke, kot so spol, starost, status zaposlitve itd, lahko uporabnik vnese preko posebnega čarovnika, ki pomaga pri personalizaciji. Ti podatki so potem na voljo vsem podjetjem.

Podjetja lahko s pomočjo Quicke izdelajo enostavne ali kompleksne večnivojske, avtomatizirane in personalizirane marketinške ter prodajne akcije. S tem ustvarijo uporabniške zgodbe, ki jih ni mogoče izdelati v nobenih drugih marketinških produktih, in tako negujejo in izboljšujejo odnose s svojimi strankami.

QuickA nudi podjetjem številne prednosti:

- pridobivanje novih kupcev in povečevanje prodaje pri obstoječih kupcih
- personalizirano in targetirano pospeševanje prodaje glede na interese in potrebe kupcev
- gradnja zasebnega odnosa med podjetjem, blagovno znamko in kupcem
- pridobivanje povratnih informacij o vedenju kupcev v realnem času
- omogoča izvajanje raziskav trga, prediktivnih analiz in zaznavanje bodočih trendov
- izboljšuje uporabniško nakupovalno izkušnjo in povečuje zadovoljstvo in zvestobo kupcev
- pomaga razumeti in spoznati kupce, kaj potrebujejo, iščejo in ljubijo
- informira kupce o novih izdelkih in identificira priložnosti za izboljšanje poslovanja

QuickA nudi uporabnikom številne prednosti:

- pridobivanje personaliziranih akcijskih ponudb kjerkoli in kadarkoli
- gradnja zasebne komunikacije s podjetjem in blagovno znamko
- sodelovanje uporabnika pri razvoju produktov, storitev in ponudbe
- pridobivanje in unovčenje točk zvestobe za najljubše blagovne znamke
- 100% anonimna uporaba, ki izboljšuje uporabniško izkušnjo ter zadovoljstvo in zvestobo kupcev

QuickA za svoje delovanje pridobiva podatke iz več različnih virov podatkov, na podlagi katerih kupcu ponuja personalizirane akcijske ponudbe, produkte in storitve:

- lastni podatki o kupcu z njegovimi interesi, željami, vedenjem, prejšnjimi in prihodnjimi nakupi, ki so pridobljeni preko uporabe mobilne aplikacije
- zunanji zasebni in javni podatki, kot so družbena omrežja, pametna mesta, naprave in transakcijski podatki.

Pridobljene informacije so razdeljene v pet ključnih sklopov za opis in ontologijo uporabnika:

- Interesni graf – (angl. Interest graph)
- Iskalni graf – (angl. Search graph)
- Lokacijski graf – (angl. Location graph)
- Graf znanja – (angl. Knowledge graph)
- Socialni graf – (angl. Social graph)

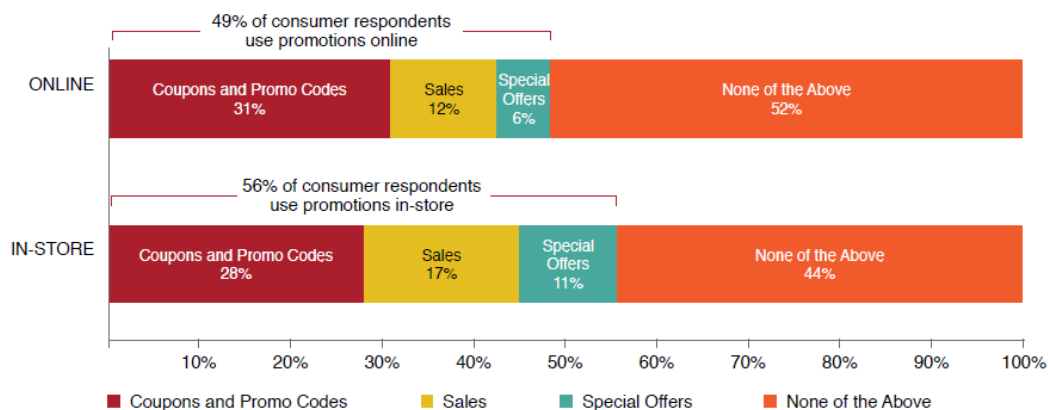
Za pridobivanje osebnih in občutljivih podatkov uporabnikov, ki se uporabljajo za personalizacijo, sem zasnoval priporočilni sistem na način, da je uporabnik za vsak odgovor ali izvedeno akcijo nagraden z akcijsko ponudbo ali točkami zvestobe. Raziskava podjetja RetailMeNot je pokazala, da je kar 49 % uporabnikov na spletu uporabilo vsaj eno vrsto posebne promocije, kot so kuponi, razprodaje ali posebne ponudbe. V fizični trgovini je uporaba teh promocij še večja, in sicer 56%. Kar 91 % uporabnikov, ki uporabljajo promocije v trgovini, je odgovorilo, da je zaradi posebne

promocije kasneje izvedlo nakup. Pri spletnih uporabnikih je nakup izdelka izvedlo kar 89 % uporabnikov. Ker uporabniki zelo radi uporabljajo posebne promocije, se mi je zdela to najboljša kompenzacija za uporabnikovo posredovanje in deljenje osebnih podatkov.

FIGURE 1

49% of Consumers Use Promotions Online; 56% of Consumers Use Promotions In-Store

Consumers answer, "In the last year, which of the following have you used when shopping (non-grocery items)?"



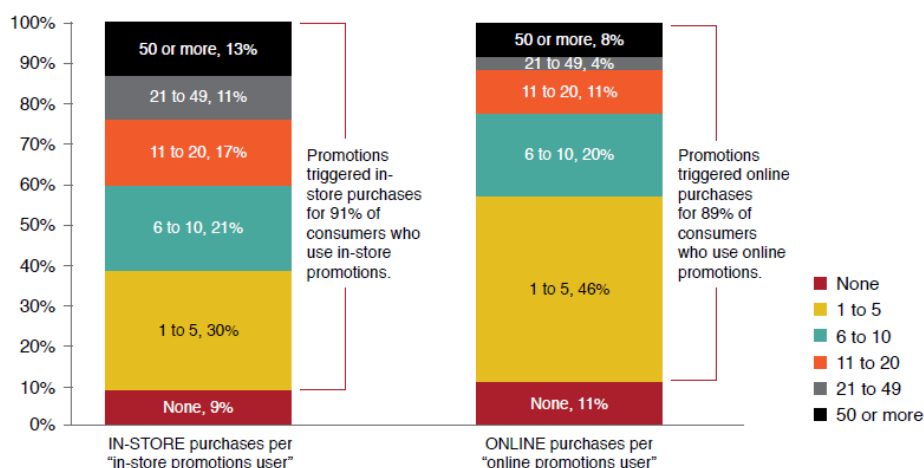
Source: RetailMeNot survey conducted using Google Consumer Surveys, August 2014. For methodology, see appendix A.

Slika 13: Raziskava podjetja RetailMeNot glede uporabe posebnih promocij

FIGURE 3

Promotions Trigger Purchases for Most Consumers

Consumers who use promotions answer, "In the last year, how many of your purchases (non-grocery) were triggered by promotions (sales, offers, coupons, etc.)?"



Source: RetailMeNot survey conducted using Google Consumer Surveys, August 2014. For methodology, see appendix A.

Slika 14: Raziskava podjetja RetailMeNot o izvedbi nakupa zaradi posebnih promocij

6.1 Načrtovanje in razvoj priporočilnega in odločitvenega sistema

Razvoj vsakega informacijskega in priporočilnega sistema zahteva uporabo določene metodologije in poteka v petih ključnih fazah:

- **Sistemska analiza in planiranje** – pri sistemski analizi specificiramo poslovne cilje in razvijemo listo funkcionalnosti ter pridobimo vse potrebne informacije.
- **Načrtovanje sistema** – v tej fazi specificiramo načrt sistema, to je podrobni opis z vsemi ključnimi komponentami v sistemu in njihova medsebojna razmerja. Načrt je sestavljen iz dveh komponent: logični in fizični model. Logični model vsebuje diagram podatkovnega toka, seznam funkcij za procesiranje in načrt podatkovne baze, opis varnosti in varnostnih kopij ter kontrol, ki se bodo uporabljale v sistemu. Fizični model prevede logični model v fizične komponente, kjer že natančno specificiramo model strežnika in programske opreme.
- **Razvoj informacijskega sistema** – v tej fazi na podlagi načrta razvijemo informacijski in priporočilni sistem.
- **Testiranje** – ko je sistem zgrajen, je potrebno pred produkcijo sistem temeljito stestirati. Pri testiranju izvajamo tri ključne teste: testiranje enot (angl. unit testing), kjer testiramo vsako enoto in modul posebej, sistemsko testiranje (angl. system testing), kjer se testira sistem kot celota, in na koncu uporabniški test sprejemljivosti (angl. user acceptance testing), ki zahteva, da vsi ključni uporabniki testno uporabljajo informacijski sistem in preverijo delovanje na testnih strežnikih.
- **Implementacija in vzdrževanje** – po implementaciji se življenjska doba sistema šele začne. Ker lahko pride do nepričakovanih napak ali izpadov, je potrebno stalno preverjanje, testiranje in popravljanje sistema [26].

6.2 Sistemska analiza in planiranje

Pri sistemski analizi sem se najprej lotil definiranja ključnega problema za podjetja in kupce. Danes se pri e-trgovanju soočajo z naslednjimi ključnimi izzivi:

- Kako pridobiti nove kupce in kako povečati prodajo obstoječim kupcem s tistimi produkti in storitvami, ki jih ti takrat potrebujejo kjerkoli in kadarkoli.
- Pomanjkanje kvalitetnih informacij o kupcih, njihovih navadah, prihodnjih nakupih, in preteklih izkušnjah privede do tega, da podjetja v realnem času nimajo vseh odgovorov na pomembna vprašanja, ki se tičejo marketinga, prodaje in poslovanja.
- Kupci imajo danes veliko možnosti za nakupovanje po različnih spletnih in fizičnih trgovinah, vendar na enem mestu ne pridobijo vseh personaliziranih ponudb z ugodnimi cenami za tiste storitve in produkte, ki jih potrebujejo ob določenem času na določenem mestu.

Po analizi in definiranju problema sem izdelal poslovni model, kjer sem opredelil poslovanje preko canvas modela in ga združil s poslovnim modelom za e-trgovanje.

6.2.1 Poslovni model za e-trgovanje

Poslovni model sestavlja skupina planiranih aktivnosti ali procesov, ki so načrtovani na način, da proizvedejo dobiček na trgu. Če želimo narediti uspešen poslovni model, moramo učinkovito razdelati osem ključnih elementov:

- Dodana vrednost (angl. value proposition) – definira, kako produkti ali storitve podjetja izpolnjujejo potrebe kupcev. Za razvoj in analizo dodane vrednosti podjetja moramo razumeti, zakaj bi kupci izbrali naše podjetje namesto konkurenčnega podjetja in kaj lahko podjetje ponudi več, česar drugi ne morejo.
- Prihodkovni model (angl. revenue model) – opisuje, kako bo podjetje služilo denar, generiralo dobiček in proizvajalo vrhunski donos na vloženi kapital. Obstaja veliko prihodkovnih model, vendar podjetja na področju e-trgovanja večinoma uporabljajo enega ali kombinacijo modelov, kot so oglaševalski model, naročniški model, transakcijska provizija, prodajni model in partnerski model.
- Tržna priložnost (angl. market opportunity) – se nanaša na tržno področje podjetja z dodano komercialno vrednostjo in celotno potencialno finančno priložnost, ki je na voljo podjetju na tem tržnem segmentu. Tržna priložnost je ponavadi razdeljena na več manjših tržnih niš. Realna tržna priložnost je definirana kot potencialni prihodek v vsaki od tržnih niš, kjer želimo tekmovati z ostalimi ponudniki.
- Konkurenčno okolje (angl. competitive environment) – se nanaša na druga podjetja, ki proizvajajo ali prodajajo podobne produkte ali storitve v istem tržnem okolju. Nanaša se na ponudbo nadomestnih produktov in potencialnih novih konkurentov na trgu ter moč in vpliv kupcev in dobaviteljev nad našim poslovanjem. Na konkurenčno okolje vpliva več faktorjev: koliko je aktivnih konkurentov, kako veliki so, kakšen je tržni delež vsakega od konkurentov, kako dobičkonosna so ta podjetja in kakšne so njihove cene. Vsako podjetje ima direktne in indirektno konkurente. Direktni so tisti, ki prodajajo produkte in storitve, ki so zelo podobni in so v istem tržnem segmentu. Indirektni konkurenti so podjetja, ki nastopajo v drugih industrijah, vendar še vedno konkurirajo indirektno, saj so lahko njihovi produkti nadomestek za naše produkte. Velika prisotnost konkurentov v nekem segmentu pomeni, da je trg zasičen in da bo težko pridelati dobiček. Pomanjkanje konkurence pa lahko pomeni, da trg še ni pripravljen ali tega sploh ne potrebuje.
- Konkurenčna prednost (angl. competitive advantage) – podjetje doseže konkurenčno prednost, ko lahko izdelava superiorni produkt ali spravi na trg produkt po nižjih cenah kot večina ostalih konkurentov. Podjetja lahko prav tako tekmujejo po obsegu, saj nekateri poslujejo na globalnem trgu, medtem ko drugi delujejo le na regionalnem ali domačem trgu. Podjetja, ki lahko zagotovijo superiorne produkte po najnižji ceni na globalnem trgu, imajo resnično konkurenčno prednost. Ena od unikatnih konkurenčnih prednosti na trgu je biti prvi na trgu (angl. first-mover).
- Tržna strategija (angl. market strategy) – ne glede na to, kako kvalitetno je podjetje, sta marketinška strategija in izvedba najpomembnejši za obstanek na trgu. Tudi najboljše ideje bodo padle na trgu, če niso ustrezno naslovljene potencialnim kupcem. Marketinška strategija je plan, ki natančno specificira, kako želimo vstopiti na trg in pridobiti nove kupce.

- Razvoj organizacije (angl. organizational development) – vsako podjetje, še posebej novo, potrebuje organizacijo za učinkovito implementacijo svojih poslovnih planov in strategij. Podjetja, ki želijo rasti hitro, potrebujejo plan za razvoj organizacije, ki opisuje, kako bo podjetje organiziralo delo, ki mora biti v prihodnje opravljeno. Tipično je organizacija razdeljena na oddelke: razvoj in proizvodnja, logistika, marketing, prodaja, podpora strankam in finance.
- Upravljaljska skupina (angl. management team) – eden najpomembnejših elementov poslovnega modela je upravljaljska skupina, ki je odgovorna, da poslovni model deluje na trgu. Močna upravljaljska skupina z izkušnjami in referencami iz tega področja daje moč poslovnemu modelu in krepi zaupanje zunanjih investitorjev [26].

6.2.2 Definiranje poslovnega modela za informacijski in priporočilni sistem QuickA


- Dodana vrednost – kot ključno dodano vrednost za uporabnike sem identificiral pridobivanje personaliziranih akcijskih ponudb za produkte in storitve, kjerkoli in kadarkoli po ugodnih cenah. Kupec bo imel možnost vzpostavitve zasebnega odnosa s podjetjem in določen vpliv na poslovanje podjetja. Za podjetje sem definiral kot ključno dodano vrednost pospeševanje prodaje s pomočjo personalizacije in pridobivanje pomembnih informacij od kupcev, ki jih zelo težko pridobimo preko drugih kanalov. Te informacije obsegajo vse od izkušenj s preteklimi nakupi do informacij o bodočih nakupih. Z integracijo mehkih podatkov, pridobljenih iz našega informacijskega sistema, in transakcijskih podatkov od podjetja lahko ustvarimo celovit 360-stopinjski pogled na kupca in na ta način izboljšamo personalizacijo.
- Prihodkovni model – uporaba mobilne aplikacije je za uporabnike brezplačna, saj s tem želimo pridobiti čim večje število aktivnih uporabnikov. Podjetja bodo plačevala 4 cente za vsako izvedeno akcijo in izdajo kupona ali točk zvestobe. Prihodki se bodo ustvarjali tudi preko oglaševanja določenih produktov in podjetij znotraj iskalnika, kjer je za prve tri prikazane rezultate potrebno plačati po 20 centov za klik. Tretji vir prihodkov so promocijska lokacijska sporočila, kjer bo podjetje plačalo za posredovanje lokacijske ponudbe, kadar bo uporabnik v bližini podjetja ali trgovine.
- Tržna priložnost – naš informacijski in priporočilni sistem se bo uporabljal na področju marketinga in prodaje, kjer se bomo usmerili predvsem na velike trgovce in druga storitvena podjetja. Podjetja za oglaševanje svojih produktov in storitev uporabljajo marketinški miksi in različne strategije za targetiranje kupcev na različnih kanalih. Ciljamo predvsem na uporabnike, ki uporabljajo spodbude s strani trgovcev za ugodnejše nakupe in se usmerjamo na celotni nakupovalni proces od zaznave, raziskovanja, evalvacije različnih možnosti, nakupa preko spleta ali v trgovini, ponakupne uporabniške izkušnje in posredovanje povratnih informacij o nakupu v realnem času.
- Konkurenčno okolje – konkurenčno okolje nam predstavljajo predvsem največji oglaševalski sistemi in družabna omrežja, ki so že uveljavljena na trgu in jih trgovci že uporabljajo v digitalnem marketingu. Konkurenca so nam tudi ponudniki kuponov, ki so že uveljavljeni na trgu. V začetni fazi pričakujemo, da bo podjetjem težko predstaviti konkurenčno prednost personalizacije, ki se dogaja v ozadju, saj je ta težko oprijemljiva.

- Konkurenčna prednost – naša konkurenčna prednost bo vključitev velikih trgovcev in podjetij v priporočilni sistem. Z integracijo naših in njihovih podatkov bomo lahko uporabnikom nudili celovito ponudbo personaliziranih akcijskih ponudb za produkte in storitve po ugodnih cenah. Uporabnik bo za vsako pridobitev kupona ali točk zvestobe v zameno posredoval določene osebne podatke. Z analizo teh podatkov bomo pridobili kvalitetnejše informacije za personalizacijo kot Google in Facebook ter na ta način izboljšali uporabniško izkušnjo, zmanjšali stroške ter čas z iskanjem produktov po različnih spletnih trgovinah.
- Tržna strategija – pri vstopu na trg bo ključnega pomena pridobitev dolgoročnih partnerjev, to so predvsem velika trgovska in oglaševalska podjetja, ter drugi ponudniki produktov in storitev. Z osebno prodajo naše personalizirane in inovativne rešitve bomo poskušali skleniti sodelovanje na področju pospeševanja prodaje in tržnih raziskav v realnem času. Uporabnike bomo pridobivali preko oglaševanja v digitalnih medijih, iskalnikih, lastne spletne strani in s pomočjo partnerskih podjetij.
- Razvoj organizacije – z rastjo aktivnih uporabnikov in prihodkov se bo povečalo število zaposlenih. Vzpostavili se bodo različni oddelki za raziskave in razvoj, nabavo, marketing, prodajo, podporo uporabnikom, finance in računovodstvo. V začetku vstopa na trg bova dva sodelavca, naloge se bodo razdelile glede na usposobljenost na določenem področju. Največji obseg dela na začetku poslovanja predstavljajo predvsem razvoj, marketing in prodaja.
- Upravljaljska skupina – v času vstopa na trg bova dva sodelavca, ki imata jasno vizijo glede usmeritve podjetja. V primeru rasti bo zelo pomembno, da za upravljanje različnih procesov v podjetju pridobimo ljudi, ki so motivirani, kreativni in sledijo zastavljenim ciljem.

6.2.3 Kanvas model

Po kanvas modelu, ki se danes uporablja za definiranje poslovnih modelov za startup podjetja, sem poslovni model opredelil kot:

- ponujena vrednost
- segmentacija uporabnikov
- distribucijski kanali
- odnosi s kupci
- viri prihodkov
- ključni viri
- ključne aktivnosti
- ključna partnerstva
- struktura stroškov



Slika 15: Graf ocene prihodkov, marže in stroškov v poslovne modelu za leto 2015

6.2.4 Analiziranje problema

Ključni problem, ki sem ga identificiral za podjetja, je pomanjkanje kvalitetnih podatkov o uporabnikih v realnem času. Pomanjkanje ali slaba kvaliteta podatkov v marketingu in prodaji onemogoča pridobivanje novih kupcev in personalizirano prodajo produktov in storitev, ki jih ti uporabniki potrebujejo ali želijo kjerkoli in kadarkoli. S tem se zmanjšuje zadovoljstvo kupcev in njihova zvestoba, kar vodi v izgubo prihodkov, saj uporabniki odhajajo h konkurenčnim podjetjem. Z identificiranim problemom sem pri treh največjih slovenskih trgovskih in turističnih podjetjih izvedel delavnico, kjer smo razčlenili problem in ponudili rešitev za zmanjšanje ali odpravo tega problema. Dobil sem potrditev, da problem pri podjetjih in trgovcih obstaja in da nekatera podjetja že iščejo rešitve na področju priporočilnih sistemov in personalizacije. Podjetja so izrazila zanimanje za poslovno sodelovanje, če bo aplikacija imela ustrezno število aktivnih uporabnikov.

Problem in rešitev sem predstavil tudi na konferenci Društva za marketing v sklopu predstavitve inovativnih rešitev za digitalno prihodnost. Identificiran problem, idejo in rešitev smo verificirali tudi preko Foruma Inovacij, ki ga je organiziral SPIRIT, kjer je naš informacijski in priporočilni sistem bil sprejet med top inovacije. Časopis Finance je poslovno idejo kar dvakrat uvrstil med Najpodjetniške ideje.

Glede identifikacije problema in dodane vrednosti za kupce sem anketiral 30 ljudi in s pomočjo ankete dobil pozitivne povratne informacije, saj je 68 % uporabnikov potrdilo, da bi kupili produkt ali storitev, če bi v času nakupa dobili personalizirano akcijsko ponudbo kjerkoli, kadarkoli in po ugodnejši ceni. Več kot 56 % jih je potrdilo, da so pripravljeni posredovati določene osebne podatke, ki bodo vplivali na boljše akcijske ponudbe, vendar le v primeru, da podjetju zaupajo, da bo

transparentno obdelovalo njihove podatke in se bodo lahko sami odločili, katere podatke želijo posredovati.

6.2.5 Študija zahtev in izvedljivosti

Pri študiji zahtev in izvedljivosti sem izvedel analize za:

- tehnološko izvedljivost
- ekonomsko izvedljivost
- pravno izvedljivost
- operacijsko izvedljivost
- časovno in projektno izvedljivost

Po analizi in potrditvi identificiranega problema pri podjetjih in kupcih, opravljeni študiji izvedljivosti ter pridobitvi pozitivnih povratnih informacij s trga, tudi od strokovne javnosti, sem se lotili naslednje faze načrtovanja sistema.

Strokovna ocenjevalna komisija na Forumu inovacij, ki so jo sestavljali trije strokovni ocenjevalci, je ocenila našo inovacijo in podala ob končni oceni naslednji opisni komentar v obliki utemeljitve ocene in predlogov ter priporočil za izboljšave.

QuickA je mobilna aplikacija, ki jo kupci uporabljajo med nakupovanjem v fizičnih trgovinah. Preko anket, kvizov, ipd. ponudnik od svojih kupcev dobi povratne informacije ter tako spremlja njihove potrebe, želje in glede na to kupcem ponudi njim prilagojene akcije in popuste. Gre za zanimiv pristop, ki ga v Sloveniji še ne poznamo. Ob uporabi učinkovitega algoritma za personalizacijo ponudb in rednem ažuriranju s strani ponudnika ima QuickA velik potencial za uspeh.

Sistem omogoča sprotno zajemanje podatkov o prodajanih izdelkih ali storitvah od strank, s čimer se lahko izboljša kakovost izdelka ali storitve. Pridobivanje mnenj kupcev je eno od problematičnih področij, saj kupci običajno niso zainteresirani sporočati svojih mnenj, kar pa inovacija rešuje z uvajanjem kuponov, kar materialno vzpodbudi kupca.

Menimo, da je inovacija zanimiva, dobra, tržno zelo zdržna, vendar ni ravno inovacija, saj so v tujini že nekatere podobne inovacije za nakupovanje, ki so bile vezane na QR- kode. Še enkrat, menimo, da je inovacija, ki se jo prodaja kot sistem, tržno zdržna in vredna produktivizacije.

Gre za še eno v vrsti mobilnih aplikacij, katerih namen je vplivati na potrošniške navade in odločitve kupcev ob njihovih različnih nakupnih aktivnostih. Čeprav bi lahko nekdo rekel, da gre za moralno sporno aplikacijo, saj nekako podzavestno vpliva na pripravljenost kupcev, da potrošijo več ali hitreje, kot bi sicer brez te aplikacije, je po drugi strani možna interpretacija, da pomaga potrošnikom, da več prihranijo in se bolj previdno odločajo o nakupih. Neodvisno od moralne interpretacije pa je jasno, da so razvijalci aplikacije naredili veliko delo in imajo vsaj v Sloveniji gotovo dobre možnosti, da se povežejo z različnimi trgovinami in iz tega naredijo dober poslovni primer.

6.3 Načrtovanje sistema

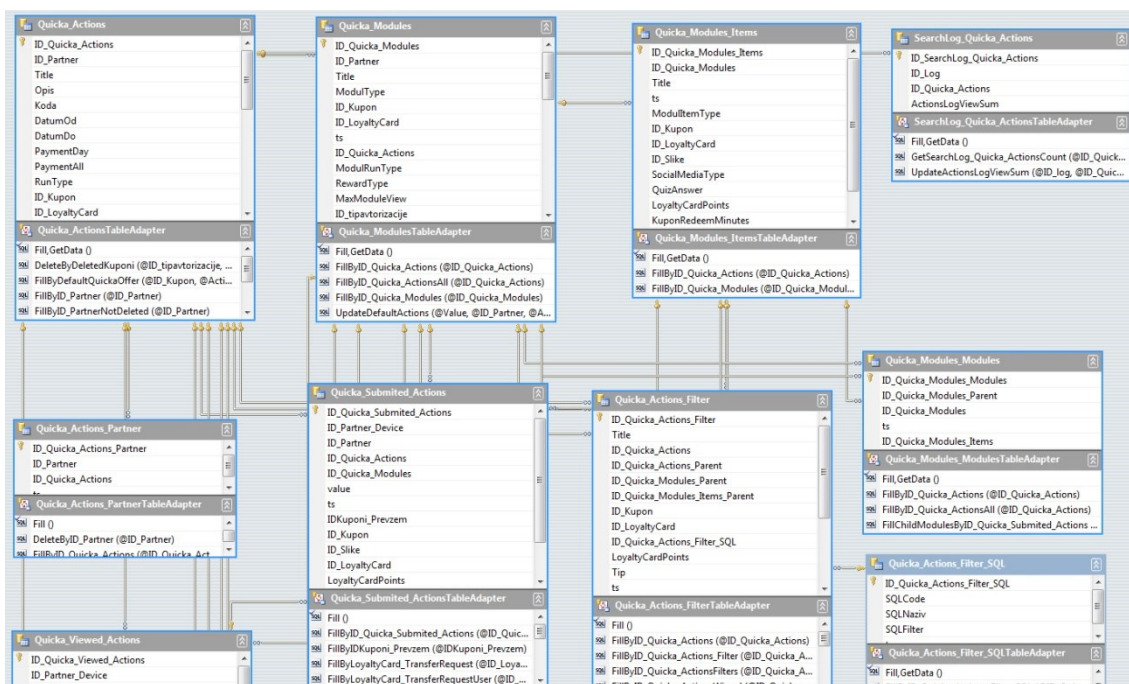
V fazi načrtovanja sistema sem najprej pripravil specifikacije informacijskega in priporočilnega sistema. Specifikacije so zajemale seznam funkcionalnosti, ki jih želimo imeti v informacijskem sistemu in mobilni aplikaciji. Za uporabniški vmesnik sem najprej izdelal mockupe z vsemi elementi uporabniškega vmesnika in jih posredoval oblikovalcu, ki je oblikoval enostavne in lepe uporabniške vmesnike za spletno stran in mobilno aplikacijo. V načrtovanju sistema sem definiral tudi arhitekturo sistema, ki je sestavljena iz:

- mobilne aplikacije QuickA
- spletnega portala za objavo akcijskih ponudb, izdelavo prodajnih akcij, urejanja nastavitvev podjetja ...
- API-vmesniki za mobilno aplikacijo in spletni portal
- aplikacijski in priporočilni strežniki v oblaku
- integracijski strežnik v oblaku
- podatkovni strežnik v oblaku

Ob definiranju seznama funkcionalnosti in arhitekture sem načrtoval tudi podatkovno bazo ter pripravil logični podatkovni model, ki je sestavljen iz 205 tabel, kjer ključni sklopi zajemajo naslednje kategorije:

- Registracija in prijava
- Uporabniki in podjetja
- Oglaševanje
- Nakup in plačevanje
- Nastavitve
- Kategorije in dejavnosti
- Ocene, komentarji, priporočila
- Produkti in storitve
- Akcijske ponudbe in kuponi
- Nakupovalna lista
- Programi zvestobe
- Prodajne akcije
- Interesni, lokacijski, socialni, iskalni graf in graf znanja
- Obvestila in e-pošta

Ob definiranju logičnega podatkovnega modela sem naredil še fizični podatkovni model, ki je že vseboval specifikacije infrastrukture in programske opreme za bazo podatkov, kjer sem izbral SQL Server od podjetja Microsoft. SQL Server je bil primarna izbira zaradi razvoja programske rešitve v programskem jeziku .NET in uporabe oblaka Microsoft Azure.



Slika 16: Prikaz podatkovnega modela za prodajne akcije

6.4 Razvoj informacijskega in priporočilnega sistema

Informacijski in priporočilni sistem je bil razvit v Microsoftovem .NET programskem jeziku C# in v tehnologiji ASP.NET za spletni del portala. Mobilna aplikacija je bila razvita kot hibridna aplikacija s tehnologijami HTML5, CSS in JQuery, saj je ta način omogočal hitrejši razvoj mobilne aplikacije za več različnih platform. Razvoj hibridnih mobilnih aplikacij ima svoje prednosti in slabosti. Prednost je predvsem enovit razvoj za več platform hkrati od (iOS, Android in Windows) ter ponovljivost, saj se lahko večino uporabljene programske kode uporabi za spletno aplikacijo. Glavna slabost so specifikne v različnih platformah, saj je prikaz in delovanje aplikacije odvisen od sofisticiranosti komponente WebView, ki jo ima posamezni operacijski sistem in znotraj katerega se izvaja aplikacija. Hibridna aplikacija je v bistvu aplikacija HTML, kjer je WebView zavrit v domorodno aplikacijsko ovojnico. Omejen je tudi nabor vtičnikov za dostop do različnih komponent naprave, zato ne moremo dostopati do vseh funkcionalnosti operacijskega sistema, vgrajenih merilnikov, kot je recimo prstni odtis, ali dostop do Healthkita v operacijskem sistemu iOS. Izvajanje hibridne aplikacije je počasnejše in ne nudi tako dobre uporabniške izkušnje kot domorodne aplikacije.

Odločitev za razvoj hibridne aplikacije je bila predvsem zaradi pomanjkanja časa in denarja. Če bi aplikacija uspela na trgu in preseгла 30.000 uporabnikov, bi bil cilj prenoviti mobilno aplikacijo v domorodno aplikacijo. Zaradi arhitekture, kjer je vsa poslovna logika razvita v oblaku, je zelo enostavno na novo razviti mobilno aplikacijo, saj je zelo malo programske kode na odjemalcu.

6.5 Funkcionalnosti informacijskega in priporočilnega sistema

6.5.1. Registracija in prijava

Za uporabo informacijskega in priporočilnega sistema se je moralo podjetje najprej registrirati preko spletnega portala, kjer si je lahko uredilo predstavitev, prodajne akcije in akcijske ponudbe. Podjetje je preko spletnega portala v postopku registracije najprej iz seznama izbralo svoje podjetje. Vsa podjetja so bila predhodno že uvožena iz registra davčnih zavezancev. V naslednjem koraku je podjetje izbralo naročniški paket, ki je lahko brezplačen ali plačljiv, odvisno od potrebnih funkcionalnosti. Po izbiri naročniškega paketa je pooblaščenec podjetja vnesel preko obrazca e-naslov, geslo, svoje kontaktne podatke in ustvaril račun za podjetje. Pooblaščenec je po uspešni registraciji na svoj elektronski naslov prejel e-pošto s povezavo za potrditev registracije. Zaradi zaščite podatkov smo uvedli še dodatno dvostopenjsko verifikacijo podjetja, kjer smo na domači naslov poslali še pristopnico z aktivacijsko kodo, ki jo je podjetje vpisalo ob prvi prijavi v sistem. Po aktivaciji in uspešni verifikaciji se je podjetje lahko prijavilo v portal in začelo urejati svoje podatke.

[Domov](#) / [Ustvarite račun](#) / [Vpis podatkov](#)

Vpis podjetja na InfoCity.si
Cenik in opis naročniških paketov
Cenik in opis dodatnih storitev
Oglaševanje
Pogosto zastavljena vprašanja
Prijava

Potrebujete podrobnejše informacije o vpisu podjetja?

[Pišite nam](#) ali nas pokličite na 01 429 33 16. Odgovore na pogosto zastavljena vprašanja si lahko ogledate [tukaj](#).



Ustvarite račun za vaše podjetje

V spodnjem obrazcu izpolnite vaše kontaktne podatke, nato pa preko varnostne kode, ki jo boste prejeli na naslov vašega podjetja, potrdite da ste odgovorna oseba za urejanje podatkov.



Vpišite podatke o računu za vaše podjetje

Podjetje:	BELI LABOD, GOSTILNA IN TRGOVINA, D.O.O.
	BIZANTOVA CESTA 22 1215 MEDVODE
E-naslov:	<input type="text"/>
Izberite geslo:	<input type="text"/>
Ime in priimek:	<input type="text"/>
Telefon ali GSM:	<input type="text"/>
Prepišite kodo:	<input type="text"/> UV2
<input type="button" value="Zaključite vpis"/>	
3 od 3	

Za pomoč ali informacije [nam pišite](#) oziroma nas pokličite na 01 429 33 16.

Ste izbrali napačno podjetje? [Ustvarite račun za vaše podjetje na InfoCity.si](#)

Slika 17: Spletni obrazec za registracijo podjetja

6.5.2. Urejanje podatkov in predstavitev podjetja

Vsako registrirano podjetje si lahko preko spletne strani uredi svoje podatke in predstavitev podjetja. Na ta način nam podjetje posreduje dragocene podatke o svojem poslovanju in ti podatki se pozneje uporabljajo pri personalizaciji. Osnovni podatki o podjetju, ki smo jih pridobili iz javnega registra pravnih oseb in samostojnih podjetnikov, namreč vsebujejo le naziv podjetja, naslov, davčno številko in glavno dejavnost. Ti podatki niso primerni za resnejšo obdelavo in personalizacijo, saj imajo lahko nekatera podjetja v nazivih zelo nenavadna imena, kot je na primer 5X d. o. o. Opredelitev glavne dejavnosti v večini primerov ne predstavlja dejanskega poslovanja podjetja in ne opiše produktov in storitev, ki jih proizvajajo ali prodajajo. Vsako podjetje si lahko preko spletne strani samostojno s pomočjo urejevalnika vsebin uredi naslednje podstrani: Predstavitev, Izkaznica, Kontakti, Reference, Storitve, Izdelki in Galerija. Znotraj teh podstrani si podjetje lahko uredi posamične vsebine:


- Kratki opis, marketinško ime, slogan, logotip
- Opis in predstavitev
- Plačilne možnosti
- Izkaznica podjetja – dolgi in kratki naziv, naslov, matična številka, davčna številka, pravni status, število zaposlenih, naslov, naselje, poštna številka, kraj, država, telefon, GSM, e-naslov, spletna stran, transakcijski račun, banka, vrsta lastnine, ustanovitelji.
- Poslanstvo, vizija, vrednote
- Trgi poslovanja
- Povezave do družbenih omrežij
- Dejavnosti podjetja
- Standardna klasifikacija dejavnosti SKD
- Delovni čas
- Oddelki, kontaktne osebe in kontakti
- Reference in mnenja strank
- Produkti in storitve
- Ceniki in katalogi
- Galerija slik
- Urejanje ključnih besed za iskalnike
- Urejanje in pregled poslovalnic
- Urejanje nastavitev za prijavo
- Dodajanje poljubnih vsebin
- Urejanje naročnine in oglaševanja

Zaradi nabora različnih podjetij ter pomanjkanja znanj iz področja računalništva ter marketinga pri določenih manjših podjetjih smo uvedli uredniški oddelek. Ta je skrbel za kvaliteto podatkov in vsebin na portalu in vsaka vsebina je pred objavo morala biti avtorizirana. V praksi smo ugotovili, da določena podjetja ne skrbijo za kvaliteto vsebin, nimajo lektoriranih vsebin ali so celo v različnih jezikih ali narečjih, fotografije so različnih velikosti in kakovosti, zato je vsaka vsebina pred objavo pregledana in potrjena ali zavrnjena. Če je urednik vsebino zavrnil, je podjetje o tem

bilo obveščeno preko e-pošte, kjer smo jih zaprosili, da vsebino popravijo in ponovno pošljejo v objavo.

Moj InfoCity.si

Pozdravljeni,
[ESTORITVE D.O.O.](#)

 Vaš naročniški paket
Platinasti paket
Veljavnost do 7.7.2017

[Lastnosti izbranega paketa](#)

Kako ste zadovoljni z InfoCity.si?
[Sporočite nam prosim svoje mnenje, težave, pripombe ali pohvale.](#)

Uredi podatke in predstavitev

Na tej spletni strani si lahko uredite podatke in predstavitev vašega podjetja. Vsaka predstavitev je sestavljena iz več spletnih podstrani, kot so: predstavitev, izkaznica, galerija, izdelki itd., od katerih vsaka vsebuje eno ali več dodanih spletnih vsebin.

SEZNAM SPLETNIH PODSTRANI ZA PREDSTAVITEV

Predstavitev
Izkaznica
Kontakti
Reference
Storitve
Izdelki
Galerija

DODANE VSEBINE - so vsebine, ki so dodane na spletno stran. Pred objavo na rumenih straneh mora vsebine potrditi urednik portala.

Kratki opis, marketinško ime, slogan, logotip	Prikaži	Uredi	Briši	Gor	Dol
Predstavitev	Prikaži	Uredi	Briši	Gor	Dol
Rešitve	Prikaži	Uredi	Briši	Gor	Dol
Plačilne možnosti	Prikaži	Uredi	Briši	Gor	Dol
Izkaznica - naziv, naslov, telefon, spletna stran	Prikaži	Uredi	Briši	Gor	Dol

PRIPOROČENE VSEBINE - so vsebine, ki jih še niste dodali na spletno stran, a jih priporočamo za kvaliteten predstavitev.

Naše poslanstvo, vizija, vrednote	Dodaj priporočeno vsebino
Poslujemo na trgih	Dodaj priporočeno vsebino
Zakaj izbrati nas?	Dodaj priporočeno vsebino
Kje nas najdete?	Dodaj priporočeno vsebino
Facebook in Twitter povezava	Dodaj priporočeno vsebino

POLJUBNE VSEBINE - so poljubne vsebine, ki jih lahko dodate na spletno stran. Izberite obliko predstavitve in vnesite podatke.

Dodaj poljubno vsebino	Dodaj poljubno vsebino
------------------------	------------------------

NAVODILA ZA UREJANJE PREDSTAVITVEV

PRIKAŽI JAVNO PREDSTAVITEV

Slika 18: Spletna stran za urejanje podatkov in predstavitev podjetja

6.5.3. Akcijske ponudbe

Ključni vir za učinkovito personalizacijo so kvalitetni podatki o uporabniku. Informacijski sistem smo zasnovali na način, da uporabnik v zameno za pridobitev akcijskih ponudb ali točk zvestobe posreduje podatke o svojih željah, potrebah, izkušnjah, bodočih nakupih ... Za različne marketinške pristope je lahko podjetje preko spletnega portala oddalo več različnih tipov akcijskih ponudb:

- Skupinske ponudbe – podjetje lahko objavi in aktivira popust za določene izdelke ali storitve po veliko ugodnejših cenah, če izdelek kupi najmanjše določeno število kupcev. Če najmanjše število kupcev ni doseženo, se trenutnim kupcem povrne rezerviran denar.
- Popusti – objava standardnih popustov od 5 do 99 % na določene izdelke ali storitve.

- Vesele urice – objava akcijskih ponudb, kjer plačaš enega ali več produktov in dobiš brezplačno še dodatni izdelek. Ta način akcijskih ponudb se uporablja predvsem v gostinstvu, trgovinah z oblačili in na dogodkih.
- Brezplačne nagrade – objava akcijskih ponudb, kjer uporabnik brezplačno pridobi določen izdelek z namenom preizkušanja. Ta način akcijskih ponudb se uporablja v kozmetiki, za brezplačne naročnine na časopise in revije itd.

Podjetje preko seznama akcijskih ponudb na spletnem portalu vidi vse svoje akcijske ponudbe, ki so lahko aktivne, pretekle, v avtorizaciji, zavrnjene ali brisane. Za objavo nove akcijske ponudbe se preko obrazca izpolnijo naslednji atributi:

- naziv, kratki in podrobnejši opis
- popust, redna cena in cena s popustom
- prikaz popusta v %, € ali prikaz cene s popustom
- področje, za katero je objavljen popust
- kontaktna oseba, e-naslov in telefon
- podjetje, naslov in kraj za unovčitev kupona, če se dejavnost izvaja na drugem naslovu
- datum veljavnosti kupona in datum objave kupona
- čas unovčenja kupona dopoldne in popoldne
- segment kupcev in vrsta kupona
- EAN-koda kupona
- maksimalno število kuponov, maksimalno število kuponov na uporabnika, velja samo za nove kupce, splošni pogoji, navodila za unovčitev kupona, spletna stran za več informacij
- fotografije in video priponke
- priljubljene akcijske ponudbe, ocene in komentarji

Po oddaji akcijske ponudbe se ponudba pošlje uredniku v avtorizacijo, ki akcijsko ponudbo pregleda in jo potrdi ali zavrne. Akcijske ponudbe se lahko odda ročno preko spletnega portala ali se jih pri večjih podjetjih množično uvozi preko API, v primeru da se akcijske ponudbe spreminjajo zelo pogosto.

Ko uporabnik preko mobilne aplikacije prevzame akcijsko ponudbo, se na kuponu izpiše unikatna 13-mestna številka kupona, s katero smo zagotovili sledljivost in validacijo kupona. Ko uporabnik unovči kupon, lahko podjetje preko API ali spletnega portala vnese unikatno številko kupona in preveri, ali je kupon veljaven in ali še ni bil unovčen. Ker je za skupinske akcijske ponudbe plačilo bilo predhodno že izvedeno preko našega informacijskega sistema, kuponi predstavljajo potrdilo o plačilu, zato smo morali zagotoviti visoke varnostne zahteve in protokole. Podjetje mora za dostop do validatorja kuponov vnesti še posebno, dodatno geslo in prav tako so vsi podatki o kuponih v podatkovni bazi kriptirani. Da bi preprečili možnost vdora v sistem in zlorabe, smo za vsako vrstico v podatkovni bazi ob vnosu ali spremembi vse attribute te vrstice združili v en niz in izračunali hash vrstice. V primeru katerekoli nepooblaščenih sprememb na vrstici, kot je recimo sprememba statusa kupona, ta vrstica ne bi bila več veljavna.

Moi InfoCity.si

Pozdravljeni,
[ESTORITVE D.O.O.](#)

Vaš naročniški paket
Platinasti paket
 Veljavnost do 7.7.2017

[Lastnosti izbranega paketa](#)

Kako ste zadovoljni z InfoCity.si?
[Sporočite nam prosim svoje mnenje, težave, pripombe ali pohvale.](#)

Moje akcijske ponudbe

Tukaj najdete seznam akcijskih ponudb, ki ste jih objavili na portalu InfoCity.si. Aktivne akcijske ponudbe so ponudbe, katerih veljavnost objave kuponov še ni potekla. Pretekle ponudbe pa so že zaključene ponudbe in so namenjene evidenci kuponov. Ponudba bo javno objavljena na portalu šele po pregledu uredništva InfoCity.si.

TIP AKCIJSKE PONUDBE: Pretekle ▼

Naziv	Veljavnost do	Število	Prikaži kupone	Uredi	Izbriši
Zeus - veliki ženski/dekliški paket (Dres + Torba + Trenirka + Bunda)	21.8.2015	0	Prikaži kupone	Uredi	Izbriši
Zeus - veliki moški/fantovski paket (Dres + Torba + Trenirka + Bunda)	21.8.2015	0	Prikaži kupone	Uredi	Izbriši
Zeus - Ženski dres TUONO - komplet majica, hlače	21.8.2015	0	Prikaži kupone	Uredi	Izbriši
Zeus - Ženski dres LYBRA - komplet majica, hlače	21.8.2015	0	Prikaži kupone	Uredi	Izbriši
Zeus - Ženski dres ITACA - komplet majica, hlače	21.8.2015	0	Prikaži kupone	Uredi	Izbriši
Zeus - Ženske kratke hlače PANTALONCINO RAFFY	21.8.2015	0	Prikaži kupone	Uredi	Izbriši
Zeus - Ženske kratke hlače PANTALONCHINO TIGER	21.8.2015	0	Prikaži kupone	Uredi	Izbriši
Zeus - Ženska srajca	21.8.2015	0	Prikaži kupone	Uredi	Izbriši
Zeus - Trenirka VIKY - 3/4 hlače	21.8.2015	0	Prikaži kupone	Uredi	Izbriši
Zeus - Trenirka TRIS NAPOLI	21.8.2015	0	Prikaži kupone	Uredi	Izbriši

Slika 19: Spletna stran seznam akcijskih ponudb

6.5.4. Produkti in storitve

Akcijske ponudbe in točke zvestobe smo uporabnikom v informacijskem in priporočilnem sistemu ponudili z namenom pospeševanja prodaje in pridobivanja dragocenih informacij o uporabnikih. Ker niso vsi produkti na voljo po akcijskih cenah, smo za celovito nakupovalno izkušnjo podjetjem omogočili promocijo vseh ostalih produktov. Z ocenjevanjem produktov, dodajanjem v priljubljene in zgodovino iskanja, smo pridobili informacije glede produktov, ki uporabnika zanimajo in na ta način pridobili dragocene podatke za personalizacijo.

Podjetje preko seznama Moji produkti vidi vse svoje produkte, ki so lahko aktivni, pretekli, v avtorizaciji, zavrnjeni ali brisani. Za objavo novega produkta se preko obrazca izpolnijo naslednji atributi:

- naziv in opis produkta
- cena produkta
- EAN-koda

- zaloga
- prikaz produkta v iskalniku
- povezava do spletne trgovine in več informacij
- slika produkta
- povezani produkti za X-sell ali Up-sell

Po oddaji produkta se produkt pošlje uredniku v avtorizacijo, ki produkt pregleda in ga potrdi ali zavrne. Produkte se lahko odda ročno preko spletnega portala ali se jih pri večjih podjetjih množično uvozi preko API, v primeru, da se produkti spreminjajo zelo pogosto.

[Moi InfoCity.si](#)

QuickA - Moji produkti

Tukaj najdete seznam vaših produktov za Quicko.

[Dodajte produkt](#)



STATUS PRODUKTA:

Naziv produkta	Cena	Datum	Poveži produkte	Uredi	Izbriši
B207N - GEL-ROCKET 6 copat	65,00	22.7.2015	<input type="button" value="Poveži"/>	<input type="button" value="Uredi"/>	<input type="button" value="Izbriši"/>
C40RQ - GEL - FLARE 5 GS CHILDREN copat	45,00	22.7.2015	<input type="button" value="Poveži"/>	<input type="button" value="Uredi"/>	<input type="button" value="Izbriši"/>
Calza Tubo nogavica (One Size)	20,00	22.7.2015	<input type="button" value="Poveži"/>	<input type="button" value="Uredi"/>	<input type="button" value="Izbriši"/>
CAMA veliki dekiški paket (Dres + Torba Best + Trenerka + Bunda)	110,00	22.7.2015	<input type="button" value="Poveži"/>	<input type="button" value="Uredi"/>	<input type="button" value="Izbriši"/>
Compression Cuff nogavica	28,00	22.7.2015	<input type="button" value="Poveži"/>	<input type="button" value="Uredi"/>	<input type="button" value="Izbriši"/>
Compression Socks nogavica	30,00	22.7.2015	<input type="button" value="Poveži"/>	<input type="button" value="Uredi"/>	<input type="button" value="Izbriši"/>
Cot Sock nogavica	30,00	22.7.2015	<input type="button" value="Poveži"/>	<input type="button" value="Uredi"/>	<input type="button" value="Izbriši"/>
ERREA nogavice	8,90	22.7.2015	<input type="button" value="Poveži"/>	<input type="button" value="Uredi"/>	<input type="button" value="Izbriši"/>
Ghost Sock nogavica	22,00	22.7.2015	<input type="button" value="Poveži"/>	<input type="button" value="Uredi"/>	<input type="button" value="Izbriši"/>
Mikasa MVA200 žoga	60,00	22.7.2015	<input type="button" value="Poveži"/>	<input type="button" value="Uredi"/>	<input type="button" value="Izbriši"/>

Rezultati 1 - 10 od skupaj 16 na strani

Slika 20: Spletna stran seznam mojih produktov

6.5.5. Programi zvestobe

Za pridobitev podatkov o uporabnikih smo v aplikaciji zastavili poslovni model, kjer smo uporabnika za vsak odgovor ali izvedeno akcijo nagradili s kuponom za akcijsko ponudbo ali s točkami programa zvestobe. Programi zvestobe so v Sloveniji zelo razširjeni, saj ima kar več kot 52 % slovenskih potrošnikov najmanj tri trgovske

kartice zvestobe in le 12 % potrošnikov ne poseduje nobene kartice zvestobe. V aplikaciji smo omogočili, da podjetje vnese v informacijski sistem vse svoje programe zvestobe in jih lahko uporabi v prodajni akciji, kjer izbere program zvestobe in določi število točk, ki jih bo uporabnik dobil z odgovorom na vprašanje ali z izvedbo akcije. Zbrane točke zvestobe lahko uporabnik kasneje uporabi za zamenjavo kakšne posebne akcijske ponudbe ali izvede prenos zbranih točk zvestobe na svojo kartico programa zvestobe in jih porabi pri nakupu v trgovini. Podjetje lahko tako svoj program zvestobe razširi izven svoje trgovine in svoje kupce nagradi za pridobljene podatke. Ob svojih klasičnih programih zvestobe si lahko podjetje izdelava posebne programe zvestobe, ki se uporabljajo le v našem informacijskem sistemu.

Podjetje preko seznama Moji programi zvestobe vidi vse svoje programe zvestobe, ki se uporabljajo v informacijskem sistemu. Za objavo novega programa zvestobe se preko obrazca izpolnijo naslednji atributi:

- naziv in opis
- spletna stran za več informacij
- splošni pogoji
- fotografija programa zvestobe

Po oddaji programa zvestobe gre program zvestobe v avtorizacijo uredniku, ki program zvestobe pregleda in ga potrdi ali zavrne.

QuickA - Moji programi zvestobe
Tukaj najdete seznam vaših programov zvestobe za Quicko.

[Oddajte nov program zvestobe](#)

Naziv	Datum	Uredi	Izbriši
Program zvestobe Zdravje	10.6.2016	Uredi	Izbriši
Program zvestobe Sveže	26.4.2015	Uredi	Izbriši

Slika 21: Spletna stran seznam mojih programov zvestobe

6.5.6. Prodajne akcije

Ena ključnih funkcionalnosti informacijskega in priporočilnega sistema je možnost objave večnivojskih komunikacijskih, marketinških in prodajnih akcij. Prodajne akcije so zgrajene kot odločitveno drevo, ki je sestavljeno iz kombinacije 12 različnih modulov in s pomočjo katerih lahko podjetje sestavi poljubno prodajno akcijo glede na svoje potrebe in želje.

Podjetje preko seznama Moje prodajne akcije vidi vse svoje prodajne akcije, ki so lahko aktivne, pretekle, v avtorizaciji, zavrjene ali brisane. Za objavo nove prodajne akcije se preko obrazca izpolnijo naslednji atributi:

- naziv in opis

- hash (#) koda
- datum veljavnosti od in do
- tip nagrade (akcijska ponudba ali program zvestobe)
- čas unovčitve kupona
- način izvajanja prodajne akcije
 - a. nadaljуй s to akcijo do konca
 - b. nadaljуй naslednjo akcijo po prioriteti
 - c. nadaljуй z naslednjo priporočeno akcijo
- prioriteta pomembnosti
- akcijo prikaži uporabniku največkrat
- akcijo izvedi uporabniku največkrat
- največja poraba in največja poraba na dan v €
- filtri prodajne akcije
- moduli prodajne akcije

Po oddaji prodajne akcije gre prodajna akcija v avtorizacijo uredniku, ki prodajno akcijo pregleda in jo potrdi ali zavrne.

[Moi InfoCity.si](#)

QuickA - Moje prodajne akcije

Tukaj najdete seznam vaših prodajnih akcij za Quicko.

Seznam prodajnih akcij

Aktivne prodajne akcije so akcije, ki se trenutno prikazujejo.



Oddajte novo prodajno akcijo

TIP PRODAJNE AKCIJE:

Naziv akcije	Veljavnost od	Veljavnost do	Ogledov	Odgovorov	Št. kuponov	Št. točk zvestobe	Moduli akcije	Filtri akcije	Uredi	Izbriši
Sveža zelenjava	10.6.2016	10.7.2016					<input type="button" value="Moduli"/>	<input type="button" value="Filter"/>	<input type="button" value="Uredi"/>	<input type="button" value="Izbriši"/>
Sveže sadje	10.6.2016	10.7.2016					<input type="button" value="Moduli"/>	<input type="button" value="Filter"/>	<input type="button" value="Uredi"/>	<input type="button" value="Izbriši"/>

Pregledajte statistiko vseh prodajnih akcij v realnem času!

Statistika vseh prodajnih akcij

Slika 22: Spletna stran seznam mojih prodajnih akcij

QuickA - Oddajte novo prodajno akcijo

Tukaj lahko oddate novo prodajno akcijo za Quicko.

Oddajte prodajno akcijo

Splošni podatki o prodajni akciji
⊞

Naziv: * Npr.: Božični popust televizorjev

Opis:

To je akcija za svežo sadje

Npr.: Ponudba v kateri bomo za 20% do 40% prodajali LCD televizorje.

Koda: Npr.: #LCD-TV - črke in številke brez presledka in z začetnim hash(#) znakom. Koda akcije preko katere lahko uporabnik enostavno najde obstoječo akcijo.

Datum od:

Datum do:

Tip nagrade:

Akcijnska ponudba:

Čas unovčitve kupona:

Način izvajanja:

Prioriteta:

Akcijo prikaži uporabniku največ:

Akcijo izvedi uporabniku največ: Akcija se izvede, ko uporabnik znotraj akcije odda vsaj 1 odgovor.

Max. poraba v EUR:

Max. poraba na dan v EUR:

Slika 23: Obrazec oddaj prodajno akcijo

6.5.7. Filtri prodajne akcije

Za vsako prodajno akcijo lahko določimo več filtrov, s katerimi še dodatno omejimo in segmentiramo prodajne akcije in jih na ta način prikažemo le ustrezni skupini uporabnikov. Podjetje preko seznama Filtri prodajne akcije vidi vse filtre, ki so vezani na posamezno prodajo akcijo. Za vsako prodajno akcijo lahko uporabimo pet tipov filtrov:

- Splošni filter, kjer lahko filtriramo:
 - a. ogled akcije – filtriramo uporabnike, ki so si ogledali določeno prodajno akcijo
 - b. odgovor na akcijo – filtriramo uporabnike, ki so sodelovali v določeni prodajni akciji
 - c. unovčili kupon – filtriramo uporabnike, ki so unovčili določen kupon

- d. doseženo število točk programa zvestobe – filtriramo uporabnike, ki so dosegli določeno število točk programa zvestobe
 - e. doseženo število točk aktivnosti – filtriramo uporabnike, ki so dosegli določeno število točk preko sodelovanja v prodajnih akcijah.
 - f. splošni filtri – prvi obisk stranke, 100 najbolj aktivnih uporabnikov ...
 - g. iskanje v zadnjem tednu – filtriramo uporabnike, ki so v zadnjem tednu iskali določene iskalne izraze
 - h. zavrnjena akcijska ponudba – filtriramo uporabnike, ki so zavrnili določeno akcijsko ponudbo
 - i. preskočil prodajni modul – filtriramo uporabnike, ki so preskočili določen prodajni modul
 - j. vreme – filtriramo glede na vremenske razmere v določenem kraju (jasno, megla, rosenje, rahlo oblačno, oblačno, ploha dežja, sneg, nevihta, toča, rosenje)
 - k. vreme temperatura – filtriramo glede na temperaturo od–do v določenem kraju
- QuickA čarovnik – filtriramo po skupnih podatkih uporabnika, ki jih dobimo preko odgovorov vprašalnika v čarovniku.
 - Ključne besede – filtriramo po ključnih besedah v interesnem grafu, kjer lahko določimo utežni faktor ključne besede.
 - Nakupovalna lista – filtriramo glede na produkte in storitve v nakupovalni listi
 - Poslovalnice – filtriramo, v katerih poslovalnicah se bodo prikazovale prodajne akcije. Nekatere poslovalnice imajo lahko zaradi svoje lokacije, stanja zaloge ali kakšnega drugega razloga različne prodajne akcije in popuste.

[QuickA - Moje prodajne akcije](#)

QuickA - Filtri prodajne akcije

Izbrana prodajna akcija: Sveža zelenjava

FILTER: Filtri prodajne akcije ▾

Oddajte filter za prodajno akcijo

Dodani filtri za prodajno akcijo

Naziv	Datum	Uredi	Izbriši
Sveže sadje	10.6.2016	<input type="button" value="Uredi"/>	<input type="button" value="Izbriši"/>
Nove stranke	10.6.2016	<input type="button" value="Uredi"/>	<input type="button" value="Izbriši"/>
Vegetarijanci	10.6.2016	<input type="button" value="Uredi"/>	<input type="button" value="Izbriši"/>

Slika 24: Spletna stran filtri prodajne akcije

QuickA - Filtri prodajne akcije

Izbrana prodajna akcija: Sveža zelenjava

FILTER: ▼

Dodajte ključne besede:

Vaše ključne besede (3)

*Ključne besede za interesni graf kupce.
Ključnim besedam lahko določite tudi pomembnost.*

Sadje [Izbriši](#) 7 ▼

Zelenjava [Izbriši](#) 9 ▼

Paradižnik [Izbriši](#) 5 ▼

Dodajte nove ključne besede:

*Dodajte ključne besede za interesni graf.
Ključne besede vnesite ločene z vejico, podpičjem ali novo vrstico.*

Vnesite ključne besede ločene z vejico npr. "okna, lesena okna" za kupce, ki se zanimaji za nakup oken.

Shrani ključne besede

Prekliči

Slika 25: Spletna stran oddaj filter za ključne besede

6.5.8. Moduli prodajne akcije

Vsaka prodajna akcija je sestavljena iz enega ali več prodajnih modulov, ki so sestavljeni v hierarhično odločitveno drevo in na ta način lahko podjetje sestavi poljubne komunikacijske, marketinške in prodajne akcije. Prodajno akcijo lahko sestavimo iz več zaporednih ali podrejenih modulov in uporabnika peljemo čez odločitveni proces glede na cilje, pravila in pogoje posamezne akcije. Prodajno akcijo lahko sestavimo iz različnih modulov:

- Anкета – sestavimo lahko poljubno anketno vprašanje iz petih možnih odgovorov z možnostjo, da dodamo še polje za vpis lastnega odgovora. Podjetje lahko označi, da je mogoče v anketi izbrati enega ali več odgovorov. Na vsak posamezni odgovor lahko dodamo podrejene module in speljemo uporabnike, ki so odgovorili na to vprašanje, na ločeno vejo odločitvenega drevesa. Uporabnik z odgovorom na anketno vprašanje pridobi ustrezno akcijsko ponudbo ali točke zvestobe
- Sporočilo – sestavimo lahko poljubno komunikacijsko ali marketinško sporočilo in uporabnik s potrditvijo ogleda sporočila pridobi ustrezno akcijsko ponudbo ali točke zvestobe.
- Sporočilo s sliko – sestavimo lahko poljubno komunikacijsko ali marketinško sporočilo z dodano fotografijo in uporabnik s potrditvijo ogleda sporočila pridobi ustrezno akcijsko ponudbo ali točke zvestobe.
- Galerija – sestavimo lahko poljubno galerijo slik in uporabnik z ogledom vseh slik v galeriji ter s potrditvijo ogleda pridobi ustrezno akcijsko ponudbo ali točke zvestobe.
- Vprašanje – sestavimo lahko poljubno vprašanje in uporabnik z odgovorom na vprašanje pridobi ustrezno akcijsko ponudbo ali točke zvestobe. Ta modul se uporablja v primeru, kadar želimo pridobiti širše in bolj poglobljene odgovore

na določena vprašanja in uporabniku ne ponudimo že preddefiniranih odgovorov kot pri anketi.

- YouTube video – objavimo lahko poljuben YouTube video posnetek in uporabnik z ogledom videa ter s potrditvijo ogleda pridobi ustrezno akcijsko ponudbo ali točke zvestobe.
- Prenesi sliko – objavimo lahko poseben izziv ali doživetje, za katerega želimo, da uporabnik posname fotografijo in nam jo pošlje v pregled. To se lahko uporablja recimo v restavraciji, kjer uporabnik v zameno za akcijsko ponudbo ali točke zvestobe posname fotografijo svojega kosila in tako lahko lastnik restavracije pridobi odzive glede na kvaliteto hrane.
- Prenesi video – objavimo lahko poseben izziv ali doživetje, za katerega želimo, da uporabnik posname video in nam ga pošlje v pregled. To se lahko uporablja recimo na kakšnih dogodkih ali turističnih izletih, kjer uporabnik v zameno za akcijsko ponudbo ali točke zvestobe posname video svojega izziva ali doživetja.
- Kviz – sestavimo lahko poljubno vprašanje za kviz iz štirih možnih odgovorov. Na vsak posamezni odgovor lahko dodamo podrejene module in speljemo uporabnike, ki so odgovorili na določeno vprašanje na ločeno vejo odločitvenega drevesa. Uporabnik z odgovorom na vprašanje kviza pridobi ustrezno akcijsko ponudbo ali točke zvestobe. Za nepravilen odgovor se uporabniku zahvalimo in v tem primeru ne dobi ničesar.
- Primerjaj produkt – objavimo lahko dva različna produkta in uporabnika povabimo, da primerja in izbere produkt, ki mu je boljši ali ljubši. Na ta način lahko testiramo določene produkte in storitve ter te pridobljene podatke uporabimo pri kasnejših odločitvah v celotnem življenjskem ciklu produkta.
- Oceni produkt – objavimo lahko produkt in uporabnika povabimo, da za ta produkt poda oceno. Na ta način lahko ocenjujemo določene produkte in storitve ter te pridobljene podatke uporabimo pri kasnejših odločitvah v celotnem življenjskem ciklu produkta. Pridobljene podatke lahko uporabimo tudi pri personalizaciji produktov, saj od uporabnika pridobimo mnenje glede določenega produkta.
- Uporabi točke zvestobe – ta modul lahko uporabimo za unovčitev točk zvestobe, ki jih je uporabnik zbral znotraj naše aplikacije. Uporabnik lahko točke zvestobe prenese na svojo kartico zvestobe pri trgovcu ali jih unovči za posebno akcijsko ponudbo znotraj aplikacije.

Podjetje preko seznama Moduli prodajne akcije vidi vse module posamezne prodajne akcije. Za objavo novega modula prodajne akcije se preko obrazca izpolnijo naslednji atributi:

- Naziv prodajnega modula
- Specifična nagrada – nagrada, ki jo uporabnik prejme za odgovor, je lahko akcijska ponudba ali točke zvestobe in se generalno definira na prodajni akciji. Če želimo na posameznem modulu narediti izjemo, se definira nagrada le za posamezni modul ali celo posamezni odgovor pri anketi, kvizu, primerjavi produktov in ocenjevanju. V primeru, da je nekdo pri anketi izbral odgovor A, lahko pridobi drugačno akcijsko ponudbo kot tisti, ki je izbral odgovor B.
- Način izvajanja – določimo, ali po unovčitvi kupona zaključimo prodajno akcijo ali jo kljub temu nadaljujemo do konca.
- Časovni zamik – pri izvajanju posameznega modula lahko izberemo možnost, da ni časovnega zamika in moduli gredo naprej glede na aktivnost uporabnika.

V primeru nastavitve časovnega zamika lahko določimo število dni časovnega zamika glede na ogled ali odgovor za ta modul. To se lahko uporabi v primeru, če je uporabnik kupil nek produkt in mu šele čez en teden ponudimo dodatne up-sell produkte. Izvajanje modula se lahko nastavi kot časovno obdobje z datumoma od in do, v katerem obdobju se bo modul izvedel. Če imamo definiran modul, ki se bo izvedel konec meseca, se izvedba te prodajne akcije zaustavi, dokler se ob koncu meseca ta modul ne bo izvedel in potem se akcija nadaljuje po pravilih naprej.

- Ura izvedbe – pri izvajanju posameznega modula lahko izberemo možnost, da se modul izvaja ves dan ali se določi ura od in do za dopoldne in popoldne, v katerem se bo izvedel prodajni modul. To je uporabno v primeru gostiln, kjer lahko v določenih urah, kadar gostilne nimajo gostov, nudijo posebne ugodnosti in na ta način zapolnijo prazne mize.
- Število točk za ogled modula – določimo število točk, ki jih pridobi uporabnik z ogledom modula.
- Število točk za izvedbo modula – določimo število točk, ki jih pridobi uporabnik z izvedbo modula ali odgovorom na vprašanje
- Modul prikaži največkrat – določimo maksimalno število prikazov posameznega modula, kjer lahko omejimo, da se nek modul znotraj posamezne prodajne akcije uporabniku prikaže največkrat dvakrat.

QuickA - Moje prodajne akcije

QuickA - Moduli prodajne akcije

Izdelajte komunikacijsko, marketinško ali prodajno akcijo s kombinacijo različnih modluov.

Izbrana prodajna akcija: Sveža zelenjava.

Prodajno akcijo lahko sestavite iz več zaporednih ali podrejenih modulov, ki so lahko različnih tipov (anketa, sporočilo, video, galerija, kviz ...).



Dodajte nov modul

Zaporedje / Naziv	Nivo / Tip	Ogledov	Odgovorov	Št. kuponov	Št. točk zvestobe	Statistika modula	Uredi	Izbriši	Dodaj podmodul
• 1. Dobrodošli v naši trgovini	1. Sporočilo					Statistika			
• 2. Koliko obrokov pojedete na dan?	1. Anketa					Statistika			
✓ Koliko obrokov pojedete na dan?									
- Odgovor: En obrok									
• 3. Video o zdravem zajtrku	2. YouTube video					Statistika			
• 4. Kakšen je vaš razlog, da ne jeste večkrat na dan?	2. Vprašanje					Statistika			
✓ Koliko obrokov pojedete na dan?									
- Odgovor: Pet obrokov									
• 5. Koliko ogljikovih hidratov pojedete na dan?	2. Anketa					Statistika			
✓ Koliko ogljikovih hidratov pojedete na dan?									
- Odgovor: 1000 g									
• 6. Prikaz nezdravega hranjenja	3. Galerija					Statistika			
• 7. Sveži paradižniki	1. Oceni produkt					Statistika			

Pregledajte statistiko prodajne akcije v realnem času in zavrnjene akcijske ponudbe!

Slika 26: Spletna stran moduli prodajne akcije

QuickA - Moje prodajne akcije / Sveža zelenjava

QuickA - Oddajte modul za prodajno akcijo

Izbrana prodajna akcija: Sveža zelenjava

Oddajte modul

Splošni podatki o modulu Sporočilo

Naziv: * Npr.: Veliko znižanje banan ...

Nastavi specifično nagrado

Način izvajanja: ▾

Časovni zamik: ▾

Ura izvedbe: ▾

Št. točk za ogled: * Število točk aktivnosti, ki jih uporabnik pridobi z ogledom modula.

Št. točk za odgovor: * Število točk aktivnosti, ki jih uporabnik pridobi z odgovorom modula.

Modul prikaži uporabniku največ: ▾

Kratko sporočilo: * Npr.: Prenovili smo ponudbo sladolediv!

Zaključiti **Prekliči**

Slika 27: Spletna stran oddajte modul prodajne akcije – sporočilo

QuickA - Oddajte modul za prodajno akcijo

Izbrana prodajna akcija: Sveža zelenjava

Izbran modul: Koliko obrokov pojedete na dan? tipa Anketa.

Oddajte modul

Splošni podatki o modulu Anketa
⊞

Naziv: * Npr.: Veliko znižanje banan ...

Način izvajanja: ▾

Časovni zamik: ▾

Ura izvedbe: ▾

Št. točk za ogled: * Število točk aktivnosti, ki jih uporabnik pridobi z ogledom modula.

Št. točk za odgovor: * Število točk aktivnosti, ki jih uporabnik pridobi z odgovorom modula.

Modul prikaži uporabniku največ: ▾

Anketno vprašanje: * Npr.: Katero sadje vam je všeč?

Odgovor A: * Npr.: Banane
 Nastavi specifično nagrado

Odgovor B: * Npr.: Hruške
 Nastavi specifično nagrado

Odgovor C: * Npr.: Jabolka
 Nastavi specifično nagrado

Odgovor D: Npr.: Maline
 Nastavi specifično nagrado

Slika 28: Spletna stran oddajte modul prodajne akcije – anketa

6.5.9. Statistika prodajnih akcij

Podjetje lahko preko seznama statistik za prodajne akcije pridobi podatke o vseh ogledih in izvedbah te akcije ter si podrobno ogleda vse odgovore, ki so jih posredovali uporabniki. Statistiko si podjetje lahko ogleda za vse prodajne akcije skupaj, za posamezno prodajno akcijo, za posamezni modul ali celo za posameznega uporabnika. Ogled statistike po posameznem uporabniku je na voljo le podjetjem, pri katerih je v prodajnih akcijah sodelovalo vsaj 250 različnih uporabnikov, saj ne želimo, da bi podjetje lahko preko odgovorov prepoznalo uporabnika, ki aplikacijo uporablja kot anonimni uporabnik. Podjetje v statistikah in poročilih ne vidi nobenega identifikacijskega podatka, ampak zmeraj dostopa le do anonimnih podatkov o uporabnikih. V statistikah in poročilih zakrijemo le identiteto uporabnika, ne pa odgovorov, ki jih je ta posredoval podjetju. Za anonimnost je

poskrbljeno tudi ob prenosu točk zvestobe k trgovcu, saj se ob vpisu e-naslova, s katerim uparimo uporabnika pri trgovcu, prenesejo le točke zvestobe in ne tudi odgovori in informacije, ki so bili pridobljeni preko prodajnih akcij. Če bi podjetju poslali tudi odgovore, bi v tem primeru podjetje lahko uparilo te uporabnike s svojimi podatki in bi to lahko zlorabili za nezaželeno oglaševanje ali v kakšne drugačne namene.

Po zaključku posamezne prodajne akcije lahko podjetje za vse uporabnike, ki so sodelovali v tej prodajni akciji, posameznem modulu, odgovoru ali pa le za določenega uporabnika doda ključne besede za kasnejšo personalizacijo. Vsaki ključni besedi se določi tudi utež in obdobje veljavnosti. Tako lahko za uporabnike, ki so v anketi odgovorili, da se zanimajo za nakup novega BMW, dodamo ključno besedo »Nakup BMW« z utežjo 9 in tej ključni besedi damo veljavnost sedem mesecev, ker je to povprečna doba nakupnega procesa novega avtomobila. Ta ključna beseda se potem sedem mesecev uporablja pri personalizaciji produktov in storitev.

[QuickA - Moje prodajne akcije](#)

QuickA - Ogled statistike po prodajnih akcijah

Tukaj najdete statistiko vaših prodajnih akcij za Quicko.

Prikazane so aktivnosti prodajnih akcij za uporabnike v realnem času.



Naziv akcije	Tip modula	Moduli akcije	Vprašanje	Odgovor	Sporočilo	Prenos	Kupon	Unovčen	Kartica zvestobe	Št. točk zvestobe	Datum in ura	Statistika uporabnika
Sveža zelenjava	Anketa	Koliko ogljikovih hidratov pojedete na dan?	Koliko ogljikovih hidratov pojedete na dan?	500 g					Program zvestobe Sveže	1	11.6.2016 10:13:01	
Sveža zelenjava	Vprašanje	Kakšen je vaš razlog, da ne jeste večkrat na dan?	Kakšen je vaš razlog, da ne jeste večkrat na dan?						Program zvestobe Sveže	1	11.6.2016 10:12:55	
Sveža zelenjava	YouTube video	Video o zdravem zajtrku							Program zvestobe Sveže	1	11.6.2016 10:12:35	
Sveža zelenjava	Anketa	Koliko obrokov pojedete na dan?	Koliko obrokov pojedete na dan?	En obrok					Program zvestobe Sveže	1	11.6.2016 10:12:25	
Sveža zelenjava	Anketa	Koliko obrokov pojedete na dan?	Koliko obrokov pojedete na dan?	Dva obroka					Program zvestobe Sveže	1	11.6.2016 10:12:25	
Sveža zelenjava	Anketa	Koliko obrokov pojedete na dan?	Koliko obrokov pojedete na dan?	Tri obroke					Program zvestobe Sveže	1	11.6.2016 10:12:25	
Sveža zelenjava	Anketa	Koliko obrokov pojedete na dan?	Koliko obrokov pojedete na dan?	Štiri obroke					Program zvestobe Sveže	1	11.6.2016 10:12:25	
Sveža zelenjava	Anketa	Koliko obrokov pojedete na dan?	Koliko obrokov pojedete na dan?	Pet obrokov					Program zvestobe Sveže	1	11.6.2016 10:12:25	

Slika 29: Spletna stran statistike prodajnih akcij

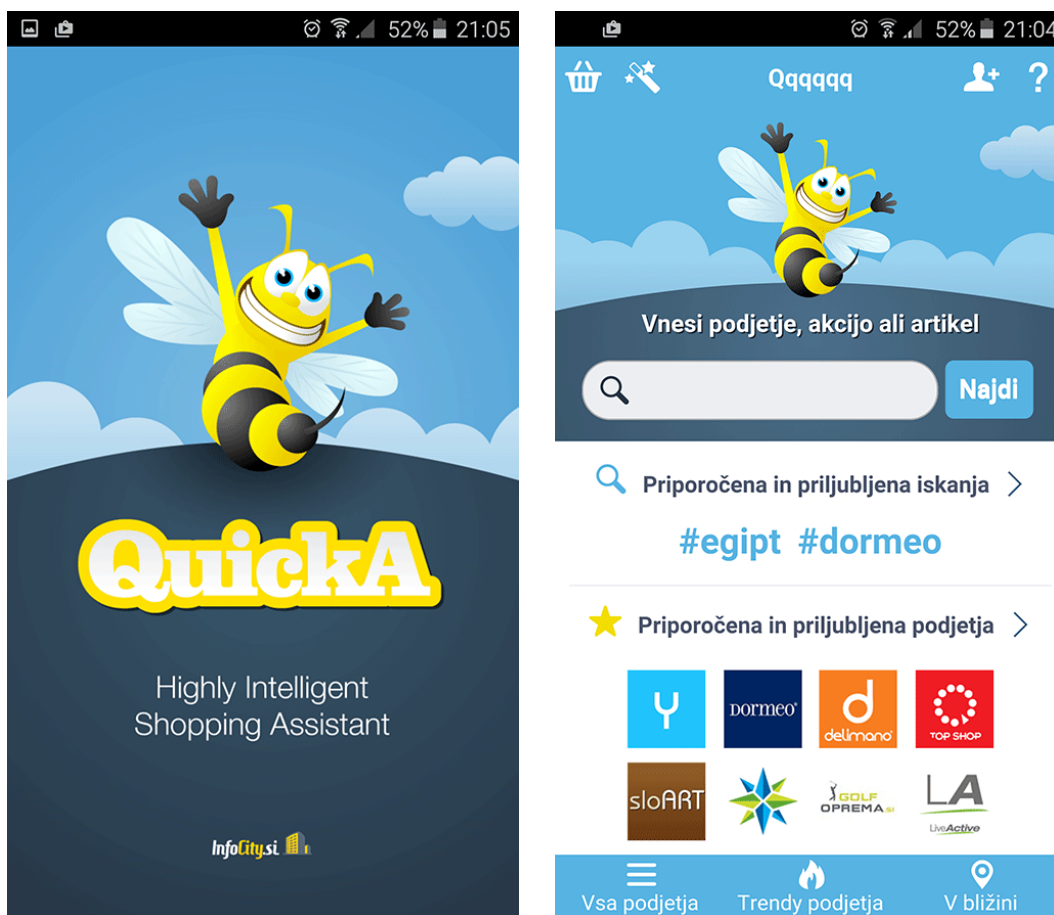
6.6 Mobilna aplikacija QuickA

QuickA je personalizirana pomočnica za nakupovanje, kjer izberete podjetje ali svojo priljubljeno blagovno znamko, sodelujete s kratkim odgovorom ali ogledom vsebine in dobite vrhunske akcijske ponudbe ali točke zvestobe.

Lahko pa brskate in iščete po ostalih produktih in storitvah v svoji bližini ter prejmete informacije o ceni, zalogi, razdalji do ponudnika in nakupujete fizično v trgovini ali preko spleta.

QuickA ima tri enostavne korake:

1. Izberete podjetje ali blagovno znamko
2. Sodelujete s kratkim odgovorom ali ogledom vsebine
3. Pridobite akcijsko ponudbo ali točke programa zvestobe



Slika 30: Splash screen in domača stran mobilne aplikacije QuickA

6.6.1 Domača stran in iskanje

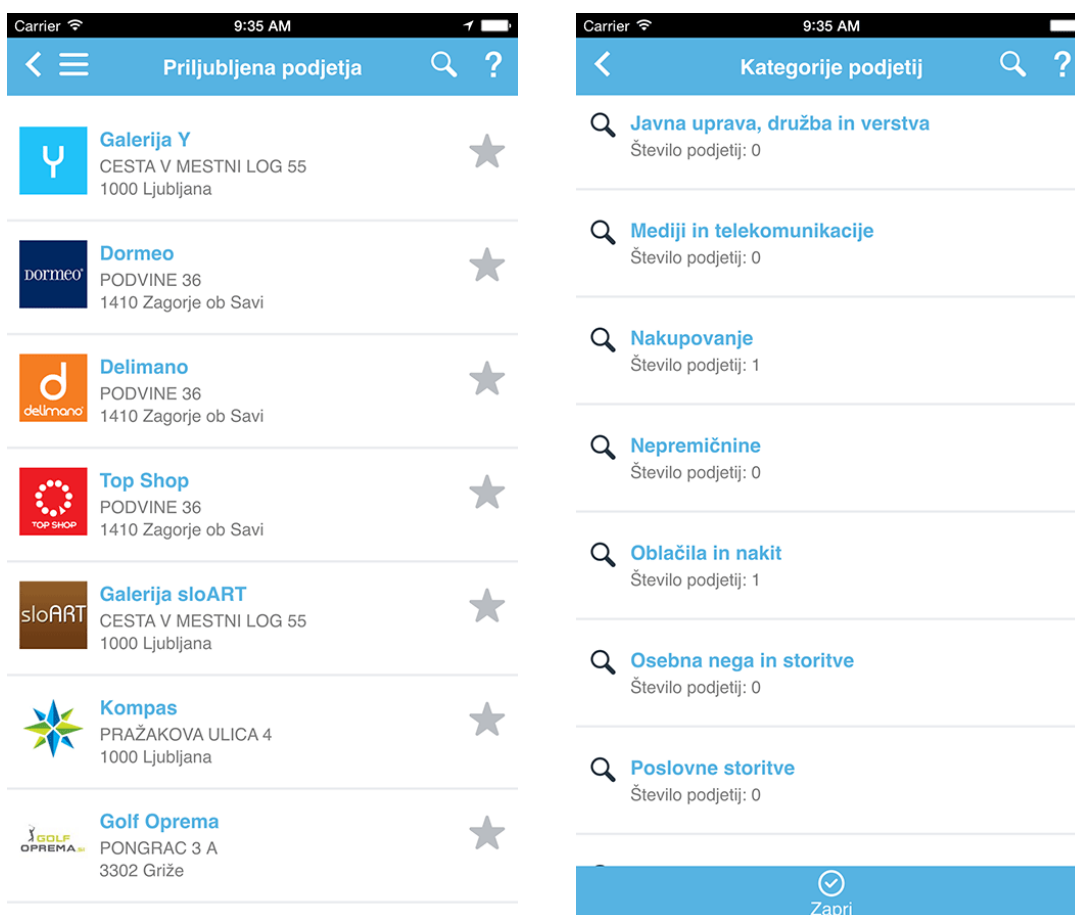
Domača stran nudi uporabniku enostaven dostop do priljubljenih podjetij in priporočenih iskalnih izrazov. V zgornji menijski vrstici imamo dostop do nakupovalne liste, dostop do čarovnika, preko katerega uporabnik posreduje svoje

splošne osebne podatke, ki so na voljo vsem podjetjem, seznam uporabnikov in pomoč. V srednjem delu ekrana imamo polje za iskanje, seznam priporočenih in priljubljenih iskanj ter seznam priporočenih in priljubljenih podjetij. V spodnji menijski vrstici imamo dostop do seznama vseh podjetij, trendovskih podjetij, kjer se trenutno unovči največ akcijskih ponudb, ter seznam podjetij v okolici, razvrščen glede na oddaljenost.

6.6.2 Priporočena in priljubljena podjetja

Preko seznama priporočenih in priljubljenih podjetij se uporabniku najprej prikažejo njegova priljubljena podjetja, ki jih je uporabnik označil z zvezdico, in na koncu seznama še priporočena podjetja, ki so personalizirana glede na skupinsko filtriranje. Če uporabnik še nima nobenega označenega priljubljena podjetja, se v seznamu prikažejo samo priporočena podjetja.

Ker mobilna aplikacija gradi dodano vrednost na zvestobi kupca in daje velik poudarek zaupanju blagovni znamki, se pri iskanju akcijskih ponudb, produktov ali podjetij v seznamu rezultatov najprej prikažejo podjetja in blagovne znamke in ne akcijske ponudbe in produkti. S klikom na izbrano blagovno znamko uporabnik pride do akcijskih ponudb in produktov. Če išče iskalni pojem »Potovanje Turčija«, se bodo uporabniku najprej v seznamu pokazala podjetja, kot so Kompas, Sonček, Collegium, uporabnik pa izbere tisto podjetje, ki mu najbolj zaupa. V naslednjem koraku uporabnik pridobi akcijske ponudbe za potovanje v Turčijo. Preko seznama produktov za izbrano podjetje si lahko pogleda vso ostalo ponudbo potovanj v Turčijo. Naš pristop se razlikuje od klasičnih primerjalnih trgovin in portalov s kuponi, kjer uporabnik vnese iskalni pojem in dobi seznam produktov in je cena ključni faktor za nakup. V seznamu podjetij lahko uporabnik s klikom na zvezdico v desnem delu doda ali odstrani podjetje iz seznama priljubljenih podjetij.



Slika 31: Priljubljena in priporočena podjetja ter seznam kategorij podjetij

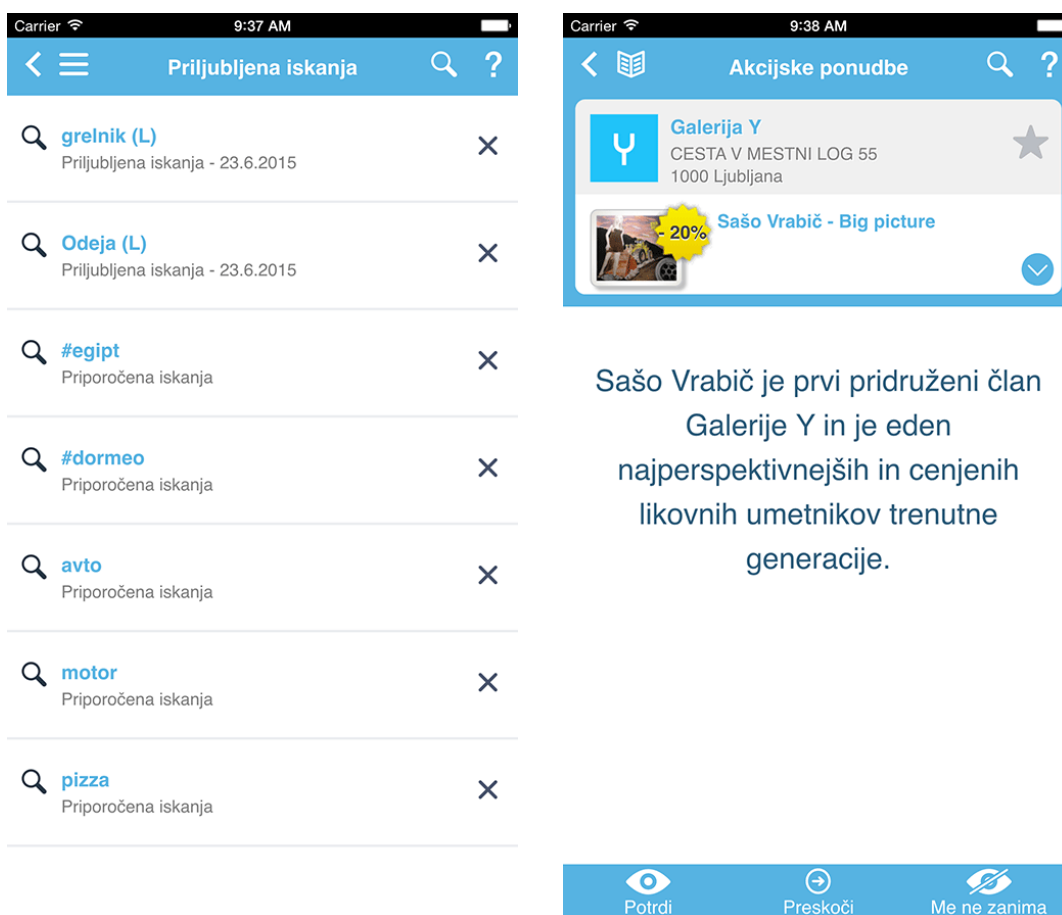
6.6.3 Kategorije podjetij

S pomočjo seznama kategorij podjetij lahko uporabnik enostavno najde podjetja v določeni kategoriji. S klikom na posamezno kategorijo se prikažejo vsa podjetja, ki so v tej kategoriji, ne glede na to, ali imajo aktivne akcijske ponudbe. Eno podjetje lahko nastopa v eni ali več kategorijah.

6.6.4 Priporočena in priljubljena iskanja

S pomočjo seznama priporočenih in priljubljenih iskanj se uporabniku najprej prikažejo njegova zadnja iskanja in na koncu seznama še priporočena iskanja. Če je uporabnik iskal določeno podjetje ali produkt v svoji okolici, se zraven iskalnega izraza izpiše še črka (L). Če uporabnik še ni izvedel nobenega iskanja, se v seznamu pojavijo samo priporočena iskanja drugih aktivnih uporabnikov. Če je uporabnik že iskal določena podjetja ali produkte, se mu najprej prikaže pet rezultatov iz zgodovine iskanja in pet rezultatov priporočenih iskanj. Na ta način uporabniku zagotovimo, da lahko ponovno enostavno najde podjetja, ki jih je mogoče iskal v centru mesta na točno določeni lokaciji in potem kasneje še od doma. Če uporabnik želi določene iskalne izraze odstraniti iz seznama, lahko klikne na gumb Odstrani v desnem delu vrstice.

Če uporabnik v iskalno polje vpiše iskalni izraz »Potovanje Turčija«, se mu bodo v rezultatih izpisala vsa podjetja in blagovne znamke, ki ponujajo potovanje v Turčijo. S klikom na izbrano podjetje se potem za to podjetje in uporabnika s pomočjo odločitvenega algoritma pridobi najprimernejša prodajna akcija, ki ustreza vsem pogojem odločitvenega drevesa in priporočilnega sistema. Če uporabnik v iskalno polje vpiše iskalni izraz z znakom hash (#turcija), se v rezultatih izpišejo le podjetja in blagovne znamke, ki so označila točno določene prodajne akcije s tem znakom. S klikom na izbrano podjetje uporabnik pride na določeno prodajno akcijo. Ta način je zelo primeren za prodajne modele O2O (angl. online to offline), kjer lahko uporabnik preko spleta, jumbo plakata, televizije ali časopisa vnese hash iskalni izraz #turcija in ob prebiranju časopisa ali gledanju televizije preko naše mobilne aplikacije prevzame kupon za akcijsko ponudbo, ki ga unovči v fizični trgovini in na ta način zagotovimo večjo prodajo.



Slika 32: Priljubljena iskanja in prodajni modul »Sporočilo«

6.6.5 Prikaz prodajne akcije – odločitveni in priporočilni algoritem za izbiro naslednje prodajne akcije in modula

Ko uporabnik izbere podjetje ali blagovno znamko, se preko posebnega algoritma izvede personalizacija, glede na pravila v odločitvenem in priporočilnem sistemu pa informacijski sistem priporoča najboljšo akcijsko ponudbo. Algoritem za priporočanje najboljše akcijske ponudbe se izvaja na naslednji način:

- Algoritem najprej preveri, ali gre za sodelovanje v prodajni akciji ali za posredovanje odgovorov preko čarovnika.
- V naslednjem koraku algoritem preveri, ali je uporabnik identificiran in ali ima vse potrebne pravice za ogled in izvedbo te prodajne akcije. Preveri se tudi, ali je podjetje, za katerega uporabnik želi izvesti prodajno akcijo, še veljavno in avtorizirano.
- Nato algoritem pridobi uporabnikovih deset zadnjih izvedenih prodajnih akcij in preveri, ali obstaja kakšen aktiven in veljaven kupon ter ga v tem primeru vrne uporabniku. Preden lahko uporabnik pridobi novo akcijsko ponudbo, se mora odločiti, ali bo ta kupon unovčil ali preklical. Uporabnik ima lahko pri enem podjetju hkrati aktiven le en kupon, saj želimo, da uporabnik kupon čim prej unovči.
- Če ni veljavnega kupona, algoritem pridobi zadnjo ogledano prodajno akcijo in glede na odločitvene pogoje poišče naslednjo prodajno akcijo ali prodajni modul.
- Nato algoritem preveri, preko katerega kanala je uporabnik prišel do posameznega podjetja, saj je prikaz prodajne akcije odvisen od različnih faktorjev. Uporabnik lahko najde podjetje preko iskanja, iskanja s kodo hash, trendovskega podjetja, podjetja v bližini ali nakupovalne liste.
- Glede na vhodne parametre algoritem pridobi za posamezno podjetje in uporabnika v prvi iteraciji 50 najprimernejših prodajnih akcij, kjer se upošteva, ali je prodajna akcija avtorizirana, ali je datum izvedbe akcije veljaven, ali je prodajna akcija presegla dnevni proračun, ali je prodajna akcija dosegla maksimalno število ogledov in ali je prodajna akcija že zaključena.
- Nato algoritem preveri, ali obstaja kakšna prodajna akcija, ki je vezana na filter za prvih pet obiskov stranke. Da ne bi podjetje takoj začelo s prodajo svojih produktov, lahko za prvih pet obiskov uporabnika definira posebne prodajne akcije, kjer uporabnika najprej lepo pozdravi in mu predstavi svojo blagovno znamko. Skozi te prve korake spodbujamo podjetje, da pridobi zaupanje uporabnika.
- Nato algoritem preveri tip izvajanja prodajne akcije in v primeru, da imamo označeno, da nadaljujemo s to prodajno akcijo do konca, algoritem poišče naslednji prodajni modul za omenjeno prodajno akcijo in ga prikaže uporabniku. Če ima prodajna akcija označeno, da nadaljuje izvajanje po prioriteti, algoritem poišče naslednjo prvo prioriteto akcijo. Če podjetje označi, da nadaljuje izvajanje z naslednjo priporočeno akcijo, algoritem poišče naslednjo priporočeno in personalizirano akcijo za uporabnika preko skupinskega ali vsebinskega filtriranja.
- Za izbrano prodajno akcijo algoritem preveri, ali je na prodajno akcijo vezan kakšen filter, ki to prodajno akcijo izloči iz nabora. Podjetje lahko preko administracije na prodajno akcijo vklopi različne filtre in s tem segmentira le tisto skupino uporabnikov, ki jim je prodajna akcija namenjena.

- Nato algoritem preveri, ali je uporabnik preskočil prodajni modul oziroma označil, da ga akcijska ponudba ne zanima. V tem primeru algoritem te prodajne akcije, module in akcijske ponudbe izloči iz nabora.
- Za izbrano prodajno akcijo nato algoritem poišče naslednji prodajni modul in v primeru, da prodajna akcija nima veljavnega modula, gre algoritem na drugo prodajno akcijo.
- Za izbiro naslednjega modula za prodajno akcijo algoritem pridobi zadnjih deset izvedenih in ogledanih prodajnih modulov, preko katerih pridobi status in zgodovino zadnjih uporabnikovih aktivnosti na tej prodajni akciji.
- Nato algoritem pridobi strukturo prodajnih modulov za to prodajno akcijo skupaj z odločitvenim drevesom. Za posamezno prodajno akcijo algoritem najprej izračuna nivo zadnjega ogledanega modula, zaporedje in maksimalno zaporedje modula. Nato algoritem preveri tip modula in v primeru, da gre za anketo, kviz, primerjavo ali oceno produkta, se na podlagi teh odgovorov pregleda, ali obstajajo kakšni podrejeni moduli, ki so vezani na te odgovore. Če podrejeni moduli ne obstajajo, algoritem poišče naslednji modul na tem ali višjem nivoju odločitvenega drevesa.
- Nato algoritem izbere naslednji modul in preveri veljavnost modula, datum in čas izvedbe modula, preveri, ali je uporabnik preskočil modul, ali je preseženo število ogledov modula, ali je nastavljen časovni zamik in ali je doseženo potrebno število točk zvestobe za prikaz modula.
- Če je izbran modul veljaven, algoritem izdela objekt `Quicka_ModulesClass` in napolni vse podatke, potrebne za prikaz prodajnega modula, akcije, podjetja, kupona in točk zvestobe. Ta objekt se potem pretvori v format JSON in se ga posreduje odjemalcu.
- Nato algoritem preveri, ali je to zadnji možen prikaz prodajnega modula v akciji. Če ni naslednjega modula, se prodajna akcija zaključi. Če akcija še ni zaključena in ima modul časovni zamik, se ta prodajna akcija začasno zaustavi in algoritem poišče naslednjo prodajno akcijo in modul.
- Če algoritem v prvem seznamu ne najde nobene primerne prodajne akcije in primerne modula za prikaz uporabniku, se rekurzivno izvede nova poizvedba, ki pridobi 50 naslednjih prodajnih akcij in jih spusti čez algoritem in filtre. Ta rekurzija se izvaja toliko časa, dokler se ne preverijo vse možne prodajne akcije za tega uporabnika in to podjetje. Če algoritem ne najde nobene prodajne akcije in prodajnega modula, uporabniku posreduje sporočilo z napako, da za to podjetje ne obstaja nobena prodajna akcija. Mobilna aplikacija uporabnika vpraša, ali želi pregledati prodajne akcije drugih podjetij, ki imajo podobno ponudbo ali ustrezajo iskalnemu izrazu.

6.6.6 Prodajni modul – Sporočilo

Ob izbiri podjetja se uporabniku prikaže prodajna akcija z modulom »Sporočilo«, ki lahko vsebuje komunikacijsko, marketinško ali prodajno vsebino. Z ogledom in potrditvijo tega sporočila uporabnik pridobi kupon za akcijsko ponudbo ali točke zvestobe. Kakšno nagrado bo uporabnik pridobil v zameno, je vidno v zgornji vrstici ekrana pod nazivom podjetja. V našem primeru je nagrada za ogledano sporočilo 20% popust na umetniško delo slikarja Saše Vrabiča. S klikom na podrobnosti akcijske ponudbe se prikažejo osnovni podatki o akcijski ponudbi, kot so cena, popust, osnovne informacije, povezava do spletne strani za več informacij in

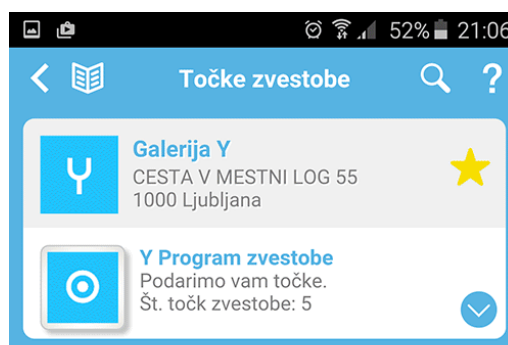
podobno. Na ta način lahko uporabnik pred sodelovanjem v prodajni akciji pogleda, ali ga nagrada sploh zanima. V spodnji vrstici ekrana ima uporabnik tri gumbе za izvedbo določene akcije. S klikom na gumb Potrdi uporabnik potrdi ogled sporočila in pridobi kupon ali točke zvestobe. Če uporabnik ne želi sodelovati v tem modulu prodajne akcije, lahko klikne na gumb Preskoči in algoritem preskoči na naslednji modul te prodajne akcije ali na drugo prodajno akcijo. Če uporabnik klikne na gumb Me ne zanima, potrdi, da ga akcijska ponudba ne zanima in v tem primeru se uporabniku ne bo več prikazovala nobena prodajna akcija, ki za nagrado ponuja to akcijsko ponudbo. Uporabnika v tem primeru v naslednjem koraku povprašamo o razlogu, zakaj ga akcijska ponudba ne zanima.

6.6.7 Prodajni modul – Sporočilo s sliko

Ob izbiri podjetja se uporabniku prikaže prodajna akcija z modulom »Sporočilo s sliko«, ki lahko vsebuje komunikacijsko, marketinško ali prodajno vsebino. To je namenjeno vsebinam, kjer želimo poudariti vizualni del sporočila. Z ogledom in potrditvijo tega sporočila uporabnik pridobi kupon za akcijsko ponudbo ali točke zvestobe.



Velika slika/Big picture



Oglejte si vrhunske umetnine
Saše Vrabčiča



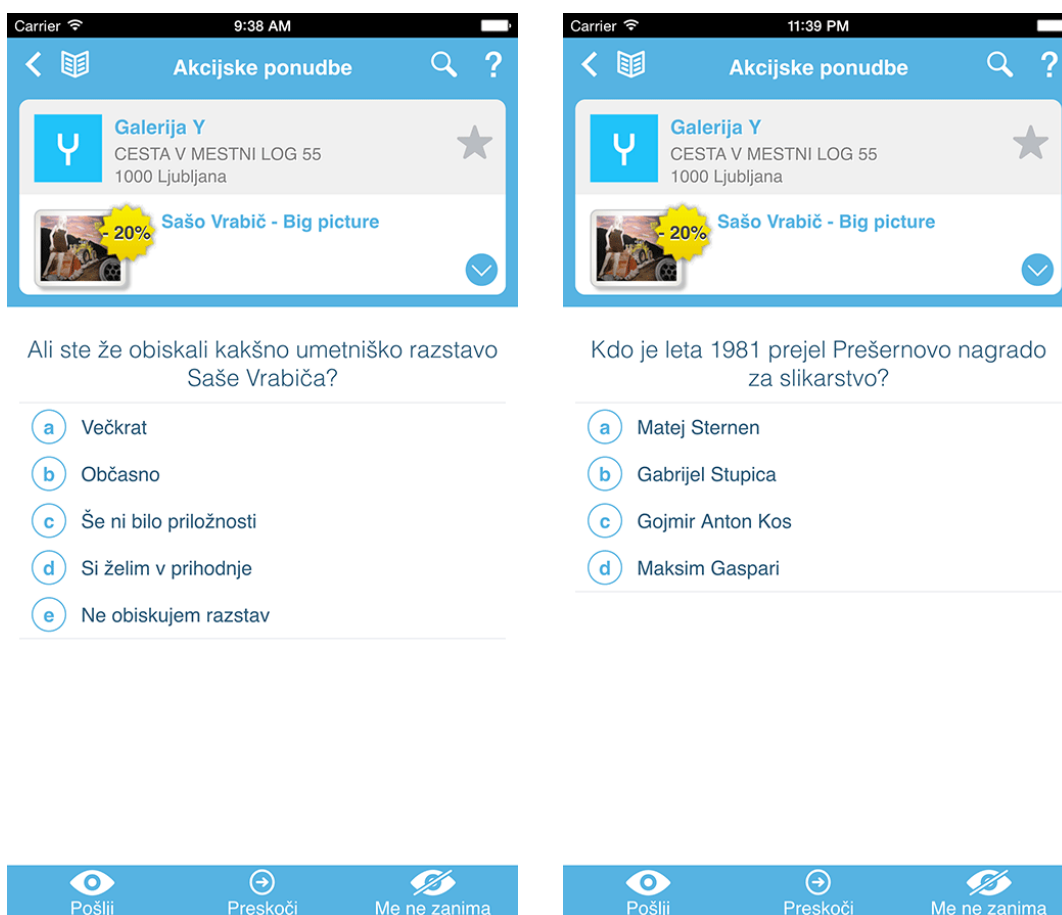
Slika 33: Prodajni modul »Sporočilo s sliko« in »Galerija«

6.6.8 Prodajni modul – Galerija

Ob izbiri podjetja se uporabniku prikaže prodajna akcija z modulom »Galerija«, ki je sestavljena iz petih fotografij produktov ali storitev. Z ogledom vseh fotografij v galeriji, kjer mora biti vsaj 2/3 vsake fotografije v vidnem polju, in potrditvijo ogleda galerije uporabnik pridobi kupon za akcijsko ponudbo ali točke zvestobe. Ta modul je primeren za prodajo turističnih ali gostinskih produktov, saj z galerijo fotografij lažje prikažemo ključne prednosti posamezne destinacije ali jedi.

6.6.9 Prodajni modul – Anketa

Ob izbiri podjetja se uporabniku prikaže prodajna akcija z modulom »Anketa«, ki je sestavljena iz vprašanja in do pet preddefiniranih odgovorov. Podjetje lahko pri izdelavi anketnega vprašanja določi, ali uporabniku ponudi možnost, da vpiše lastni odgovor in označi, ali je možen en ali več odgovorov na vprašanje. Z odgovorom na anketo uporabnik pridobi kupon za akcijsko ponudbo ali točke zvestobe. Podjetje lahko na posamezni odgovor veže različne akcijske ponudbe ali točke zvestobe. Če je nagrada odvisna od izbire odgovora, potem uporabniku ne pokažemo nagrade takoj, ampak se pokaže obvestilo, da je nagrada še zaklenjena in bo podeljena glede na izbran odgovor. To se uporablja v primeru, če bi uporabnika vprašali »Kam želite letos na dopust?« Če so možni odgovori Grčija, Španija, Italija, Egipt in Turčija, bo uporabnik dobil specifično akcijsko ponudbo glede na posredovan odgovor. Prav tako se glede na posamezni odgovor spremeni izvajanje prodajne akcije, saj lahko za posamezni odgovor pripravimo svojo vejo odločitvenega drevesa in tako uporabnikom, ki so izbrali Grčijo, ponujamo le vsebine, ki so povezane z Grčijo. Znotraj te veje odločitvenega drevesa lahko preko različnih modulov pridobimo vse informacije o uporabniku, kdaj želi na potovanje, kaj bi želel početi v Grčiji in tako z vsakim odgovorom vedno bolj personaliziramo akcijske ponudbe za Grčijo.



Slika 34: Prodajni modul »Anketa« in »Kviz«

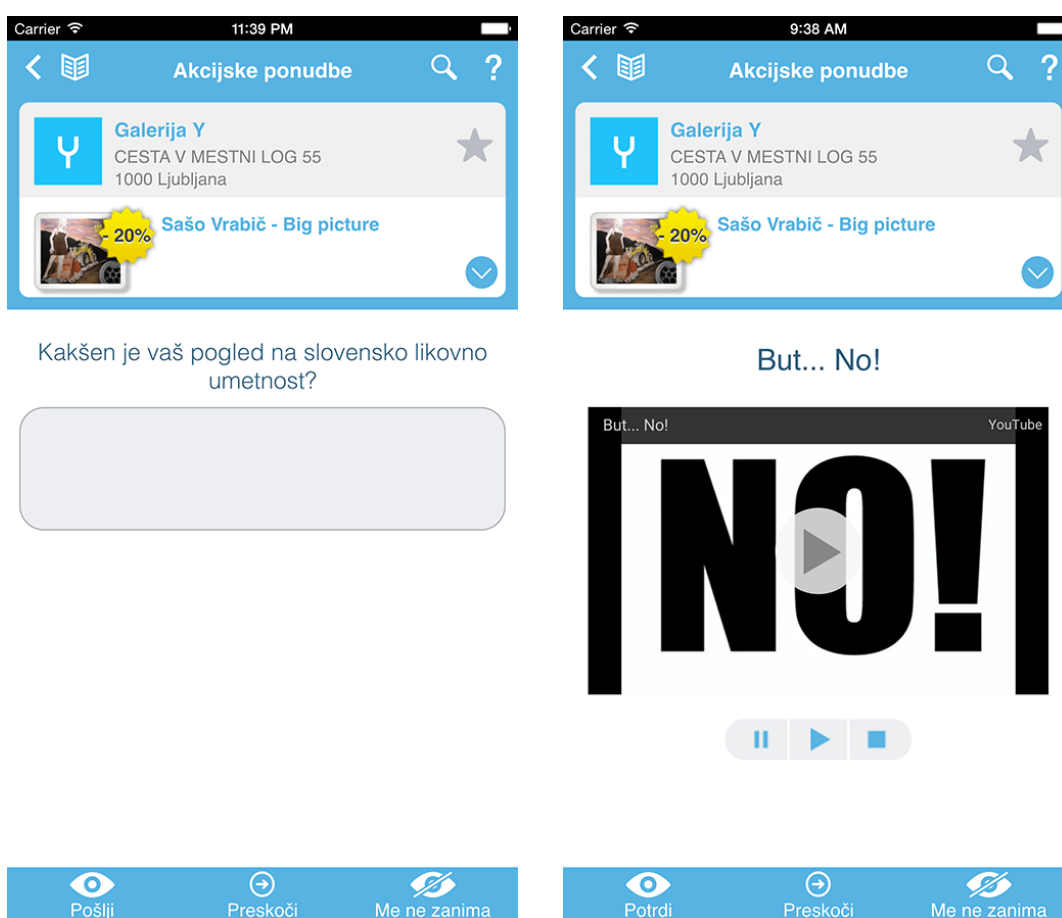
6.6.10 Prodajni modul – Kviz

Ob izbiri podjetja se uporabniku prikaže prodajna akcija z modulom »Kviz«, ki je sestavljena iz vprašanja in štirih preddefiniranih odgovorov. Podjetje pri izdelavi vprašanja za kviz določi tudi pravi odgovor. S pravilnim odgovorom na kviz uporabnik pridobi kupon za akcijsko ponudbo ali točke zvestobe. Če je odgovor napačen, uporabnik dobi le zahvalno sporočilo in v tem primeru ne dobi nagrade. Prav tako se glede na posamezni odgovor spremeni izvajanje prodajne akcije, saj lahko za posamezni odgovor pripravimo svojo vejo odločitvenega drevesa in tako uporabnikom, ki so izbrali določen odgovor, ponujamo le vsebine, ki so povezane s tem odgovorom. Ta modul je primeren predvsem za razna vprašanja o podjetju, blagovnih znamkah, produktih in storitvah, saj lahko podjetje pridobi informacije, koliko in kako uporabniki poznajo zgodovino podjetja, blagovne znamke in njihove produkte ter storitve.

6.6.11 Prodajni modul – Vprašanje

Ob izbiri podjetja se uporabniku prikaže prodajna akcija z modulom »Vprašanje«, na katerega uporabnik odgovori s poljubnim odgovorom. Z odgovorom na vprašanje uporabnik pridobi kupon za akcijsko ponudbo ali točke zvestobe. Ta modul je

primeren predvsem za splošna vprašanja, s katerimi podjetje pridobi informacije o marketingu, prodaji, poslovanju in podpori uporabnikom. Uporabniki lahko z odgovorom na vprašanje podajo daljše in splošnejše odgovore kot pri anketi, kjer so odgovori že preddefinirani in jih uporabnik mora izbrati. Ta modul se lahko uporabi za razne namene, na primer v turizmu, kjer uporabnika, ko se prijavi v hotel, povprašamo, kako je zadovoljen s sobo v hotelu, namestitvijo in z dosedanjo izkušnjo. Podjetje lahko tako v realnem času pridobi dragocene informacije in uredi vse težave uporabnikov že na samem potovanju in na ta način prihrani pri stroških reklamacije in s tem izboljša uporabniško izkušnjo.



Slika 35: Prodajni modul »Vprašanje« in »Video vsebina«

6.6.12 Prodajni modul – Video vsebina

Ob izbiri podjetja se uporabniku prikaže prodajna akcija z modulom »Video vsebina«, kjer si uporabnik ogleda video posnetek. Z vsaj 15-sekundnim ogledom video posnetka in potrditvijo ogleda uporabnik pridobi kupon za akcijsko ponudbo ali točke zvestobe. Ta modul je primeren predvsem za marketinške in prodajne

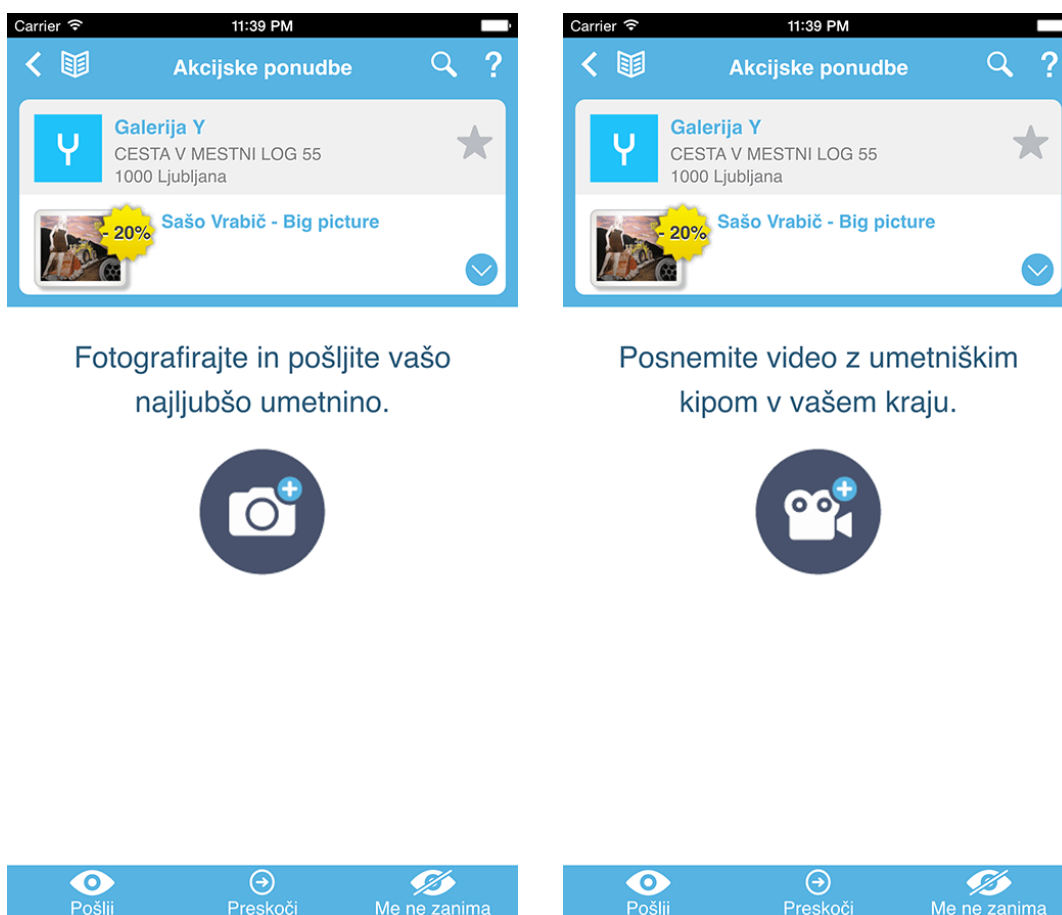
akcije, kjer lahko s pomočjo video vsebine podrobneje predstavimo določene produkte ali storitve. Kvalitetna video vsebina ima večjo marketinško in prodajno konverzijo, zato je uporaba videa v prodajni akciji zelo pomembna predvsem za prednakupno fazo.

6.6.13 Prodajni modul – Posnemite fotografijo

Ob izbiri podjetja se uporabniku prikaže prodajna akcija z modulom »Posnemite fotografijo«, kjer uporabnik dobi navodilo za posnetek fotografije določenega izziva ali doživetja. S posnetkom fotografije in prenosom na strežnik uporabnik pridobi kupon za akcijsko ponudbo ali točke zvestobe. Ta modul je primeren za trgovine ali restavracije za preverjanje kontrole kakovosti, kjer uporabnik posname fotografijo svojega kosila in na ta način lahko lastnik restavracije pridobi odzive glede kakovosti postrežene hrane.

6.6.14 Prodajni modul – Posnemite video

Ob izbiri podjetja se uporabniku prikaže prodajna akcija z modulom »Posnemite video«, kjer uporabnik dobi navodilo za izdelavo video posnetka za določen izziv, dogodek ali doživetje. S prenosom video posnetka na strežnik uporabnik pridobi kupon za akcijsko ponudbo ali točke zvestobe. Ta modul je primeren za turistična podjetja, kjer lahko uporabnik posname določeno pozitivno ali negativno izkušnjo na potovanju ali kakšno zanimivo doživetje. Te materiale lahko kasneje uporabljamo v razne promocijske namene v drugih marketinških kanalih.



Fotografirajte in pošljite vašo
najljubšo umetnino.

Posnemite video z umetniškim
kipom v vašem kraju.

Slika 36: Prodajni modul »Posnemite fotografijo« in »Posnemite video«

6.6.15 Prodajni modul – Izberite produkt

Ob izbiri podjetja se uporabniku prikaže prodajna akcija z modulom »Izberite produkt«, kjer ima uporabnik možnost izbrati določen produkt in oddati komentar. Z izbiro produkta uporabnik pridobi kupon za akcijsko ponudbo ali točke zvestobe. Na ta način lahko na trgu predhodno testiramo določene produkte in storitve ter te podatke uporabimo pri odločitvah v celotnem življenjskem ciklu produkta. Prav tako se glede na izbiro produkta A ali B spremeni izvajanje prodajne akcije, saj lahko za posamezen produkt pripravimo svojo vejo odločitvenega drevesa in tako uporabnikom, ki so izbrali določen produkt, ponujamo le vsebine, ki so povezane s tem produktom.

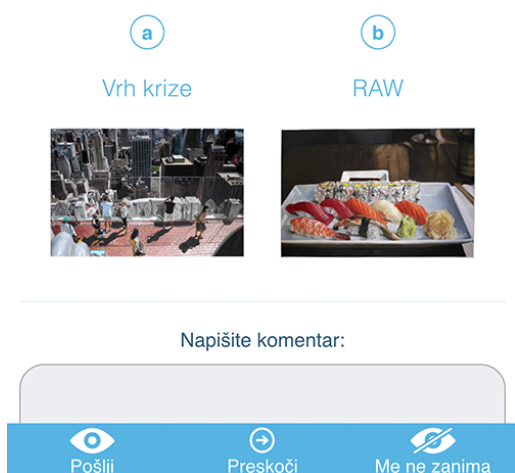
6.6.16 Prodajni modul – Ocenite produkt

Ob izbiri podjetja se uporabniku prikaže prodajna akcija z modulom »Ocenite produkt«, kjer ima uporabnik možnost oceniti določen produkt in oddati komentar. Z oceno produkta uporabnik pridobi kupon za akcijsko ponudbo ali točke zvestobe. Na ta način lahko pridobimo ocene in mnenja za določene produkte in storitve ter te podatke uporabimo pri odločitvah v celotnem življenjskem ciklu produkta. Pridobljene podatke uporabimo pri personalizaciji produktov, saj pridobimo ocene uporabnika glede določenih produktov in na ta način izvemo, kateri produkti so

uporabniku všeč in kateri niso. Prav tako se glede na oceno produkta, ki je lahko med 1 in 5, lahko spremeni izvajanje prodajne akcije, saj lahko za posamezno oceno produkta pripravimo svojo vejo odločitvenega drevesa in tako uporabnikom, ki so ocenili produkt z 1 ali 2, postavimo dodano vprašanje, zakaj jim produkt ni všeč.



Katero umetniško sliko Saše Vrabiča bi raje obesili na vašo steno?



Kako bi ocenili umetniško sliko Saše Vrabiča?



Slika 37: Prodajni modul »Izberite produkt« in »Ocenite produkt«

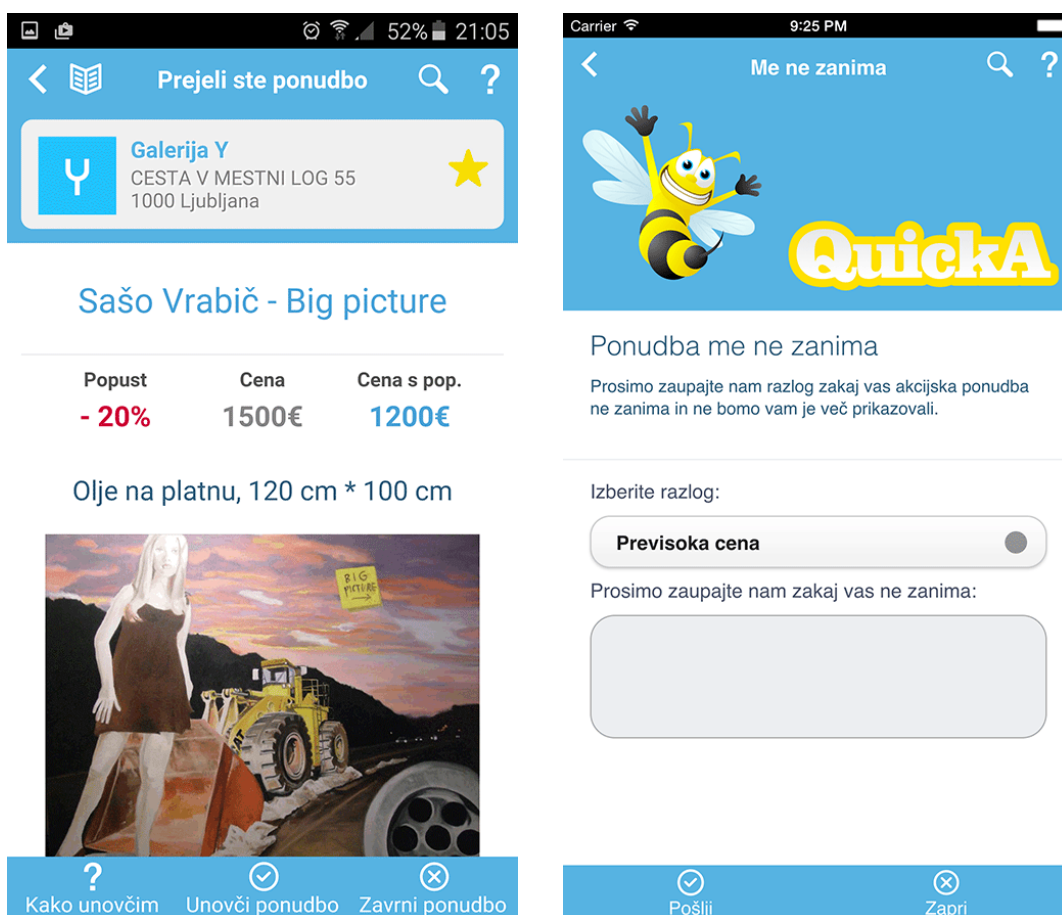
6.6.17 Prejeli ste akcijsko ponudbo

Uporabnik s poslanim odgovorom (anketa, kviz, vprašanje, oceni produkt, izberi produkt, posnemi fotografijo, posnemi video) ali ogledom vsebine (sporočilo, sporočilo s sliko, YouTube video) pridobi akcijsko ponudbo, ki je lahko personalizirana ali segmentirana glede na pravila v odločitvenem drevesu. Uporabnik v naslednjem koraku pridobi vse potrebne informacije o akcijski ponudbi: popust, cena, cena s popustom, unikatna šifra kupona, črtna koda kupona, splošne informacije o pogojih unovčitve, datum veljavnosti kupona, fotografijo in še druge informacije. Uporabnik ima lahko za posamezno podjetje le en aktivni kupon in v primeru, da ob prevzemu kupona aplikacijo zapre, se potem pri ponovni uporabi aplikacije s klikom na posamezno podjetje ta kupon ponovno prikaže. Uporabnik lahko preko spodnje menijske vrstice kupon za akcijsko ponudbo unovči ali zavrne. Unovčitev kupona pri večjih podjetjih je avtomatizirana s pomočjo skenerja, v primeru manjših količin pa podjetje z ročnim vnosom šifre kupona v validator kuponov na našem spletnem portalu preveri, ali je kupon še veljaven in ali je že bil

uporabljen. Za manjša podjetja, ki imajo malo število uporabnikov in jim upravljanje kuponov ni tako pomembno, saj si želijo s kuponom kupca le privabiti v trgovino, pa unovčitev kupona poteka tako, da uporabnik trgovcu le pokaže veljaven kupon in uporabnik sam pritisne na gumb »Unovči ponudbo« na mobilni aplikaciji. Validacija in potrditev kupona je v tem primeru na strani uporabnika. Statistika uporabe vseh izdanih in uporabljenih kuponov je podjetju na voljo preko spletnega portala.

6.6.18 Ponudba me ne zanima

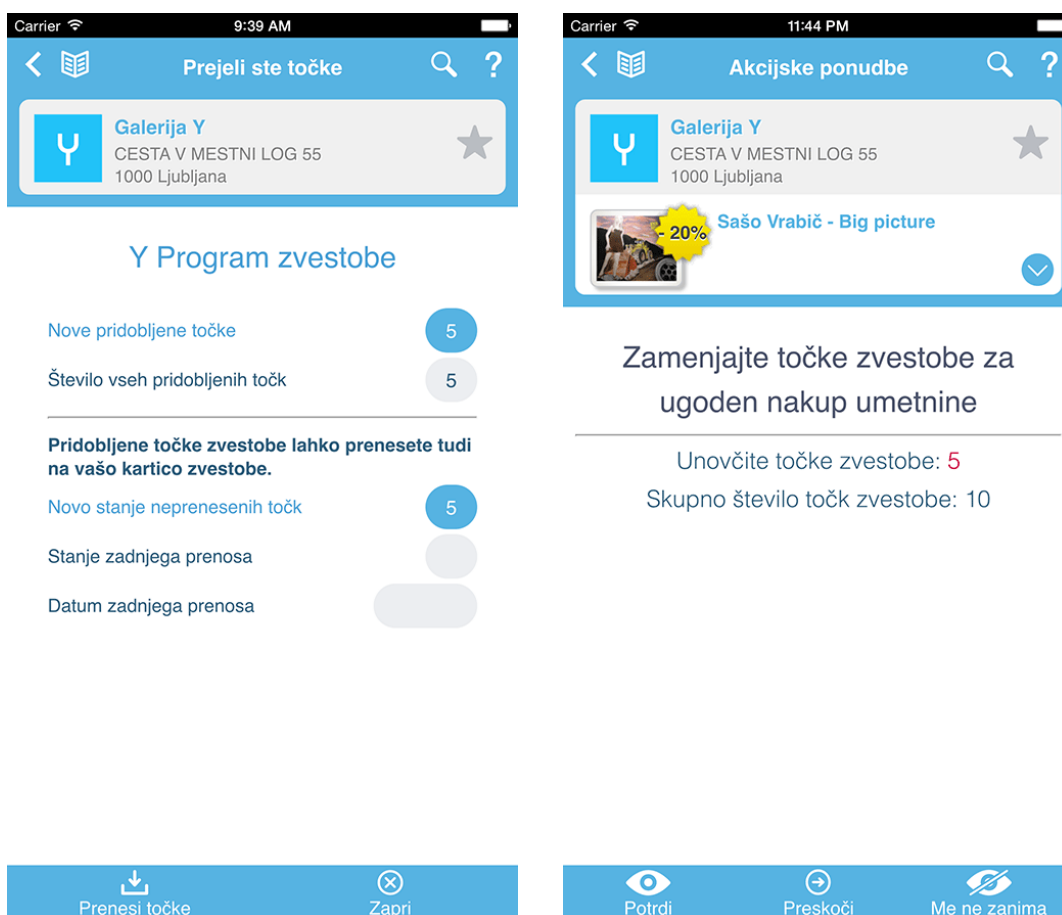
Ob izbiri podjetja se uporabniku prikaže prodajna akcija z določenim modulom in v zameno za odgovor uporabnik pridobi akcijsko ponudbo ali točke zvestobe. Če uporabnika akcijska ponudba ne zanima, lahko klikne na gumb »Ponudba me ne zanima« in zavrne to akcijsko ponudbo. To se zgodi v primeru, če je uporabnik vegetarijanec in pridobi ponudbo za mesna kosila ali če pridobi akcijsko ponudbo za nov TV-sprejemnik, čeprav je pred kratkim kupil novega. Ko uporabnik zavrne določeno akcijsko ponudbo, s tem postanejo neaktivne vse prodajne akcije ali moduli, ki za nagrado nudijo to akcijsko ponudbo. Uporabnika po zavrnitvi akcijske ponudbe preusmerimo na poseben obrazec, kjer lahko vpiše razlog in podrobnejši opis, zakaj ga akcijska ponudba ne zanima (previsoka cena, pred kratkim kupil produkt, ti produkti ga sploh ne zanimajo). Posamezni razlogi vplivajo tudi na algoritem prikazovanja akcijskih ponudb, saj lahko v primeru zavrnitve zaradi previsoke cene in kasnejšega znižanja cene algoritem uporabniku ponovno prikaže to akcijsko ponudbo. Te podatke uporabljamo tudi za dodatno segmentacijo kupcev in personalizacijo akcijskih ponudb. Če nekdo zavrne akcijsko ponudbo, ker je alergičen na paradižnik, mu v prihodnje ne bomo več ponujali akcijskih ponudb za paradižnik.



Slika 38: Prejeli ste akcijsko ponudbo in obrazec za vpis razloga »Ponudba me ne zanima«

6.6.19 Prejeli ste točke zvestobe

Ob izbiri podjetja se uporabniku prikaže prodajna akcija z določenim modulom in v zameno za odgovor uporabnik pridobi akcijsko ponudbo ali točke zvestobe. Če so nagrada za odgovor točke zvestobe, uporabniku na ekran izpišemo število novih pridobljenih točk, število vseh neprenesenih točk, število vseh pridobljenih točk ter informacije o zadnjem prenosu točk na kartico zvestobe. Uporabnik lahko pridobljene točke zvestobe uporabi v aplikaciji, kjer zamenja točke zvestobe za posebno akcijsko ponudbo. Za prodajno akcijo lahko podjetje nastavi filtre, da se akcijska ponudba aktivira v primeru, ko uporabnik doseže 1000 točk programa zvestobe in v zameno določi akcijsko ponudbo. Če uporabnik pridobljenih točk zvestobe ne želi zamenjati za akcijsko ponudbo, jih lahko prenese na kartico zvestobe s klikom na gumb Prenesi točke v spodnji menijski vrstici.



Slika 39: Prejeli ste točke zvestobe in modul za zamenjavo točk zvestobe za posebno akcijsko ponudbo

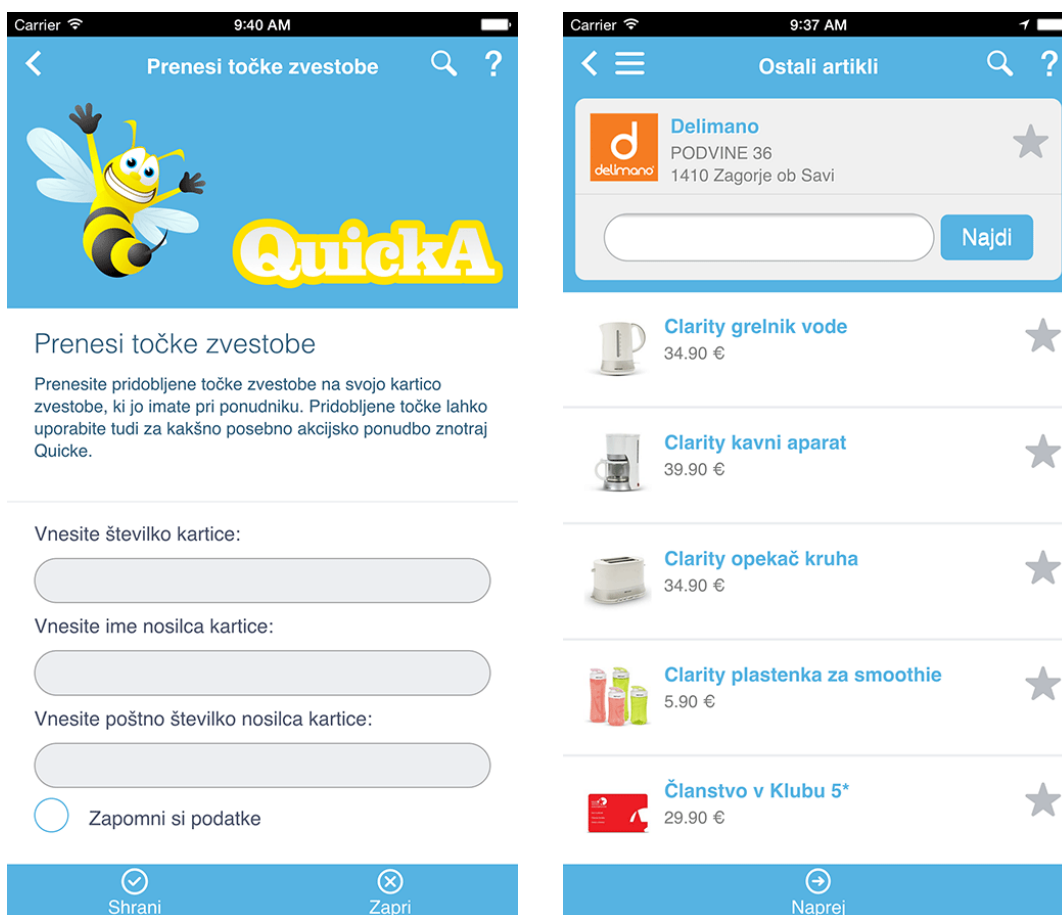
6.6.20 Prenos točk zvestobe na kartico zvestobe

Uporabnik, ki je pri podjetju pridobil za nagrado točke zvestobe za posamezni program zvestobe, lahko te točke prenese na kartico zvestobe pri podjetju ali trgovcu. S klikom na gumb Prenesi točke se odpre obrazec, kamor uporabnik vnese številko kartice zvestobe, ime in poštno številko nosilca kartice. S številko kartice zvestobe identificiramo uporabnika in z ostalima podatkomoma poskušamo preprečiti zlorabe v primeru, da bi nekdo na spletu našel številko kartice zvestobe in poskušal zlorabiti sistem. Kadar uporabnik pošlje zahtevek za prenos, se izdelava paket urnih zahtevkov, ki ga prenesemo na podjetje preko funkcije API. Podjetje ali trgovec v svojem sistemu zvestobe uporabniku prišteje točke na kartico zvestobe, ki jih lahko uporabi pri trgovcu. Podjetje preko prenosa točk zvestobe ne pridobi nobenih drugih podatkov.

6.6.21 Ostali produkti

Akcijske ponudbe omogočajo pospeševanje prodaje, vendar podjetja v akcijski ponudbi nimajo vseh produktov, ki jih uporabniki iščejo, zato smo za celovito nakupovalno izkušnjo dodali v sistem še vse ostale produkte po normalnih cenah. Uporabniki lahko tako od doma, na poti ali v trgovini najdejo produkt, ki ga

potrebujejo. Do produktov v mobilni aplikaciji lahko uporabnik pride preko iskalnika, seznama kategorij produktov ali seznama vseh produktov pri določenem podjetju. Uporabnik v seznamu produktov vidi naziv produkta, ceno in sliko. Uporabnik lahko vsak produkt doda v priljubljene in preko tega podatka pridobimo seznam ostalih produktov za personalizacijo.



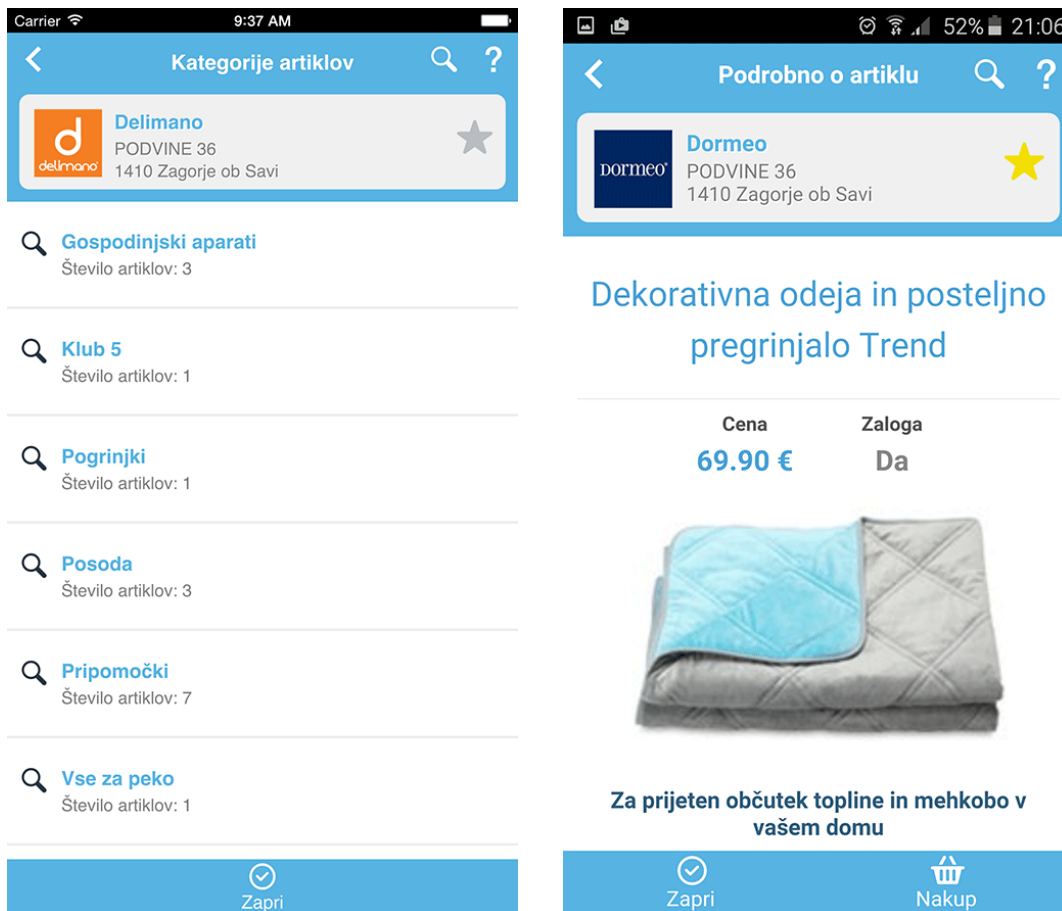
Slika 40: Prenos točk zvestobe na kartico zvestobe in seznam produktov

6.6.22 Kategorije produktov

Seznam kategorij produktov omogoča uporabniku, da preko določenih kategorij lažje najde produkte, ki ga zanimajo. Vsako podjetje lahko definira svoje lastne kategorije, kot jih na primer uporablja v svoji spletni trgovini. Produkte lahko podjetje doda v informacijski sistem ročno preko obrazca ali jih uvozi preko funkcij API. To velja predvsem za večja podjetja, ki pogosto spreminjajo produkte in cene.

6.6.23 Podrobno o produktu

Uporabnik lahko s klikom na posamezni produkt pregleda podrobnosti o produktu in vse ostale informacije glede nakupa, cene, zaloge ter povezanih produktov. S klikom na gumb Nakup enostavno pride v spletno trgovino trgovca in opravi nakup.



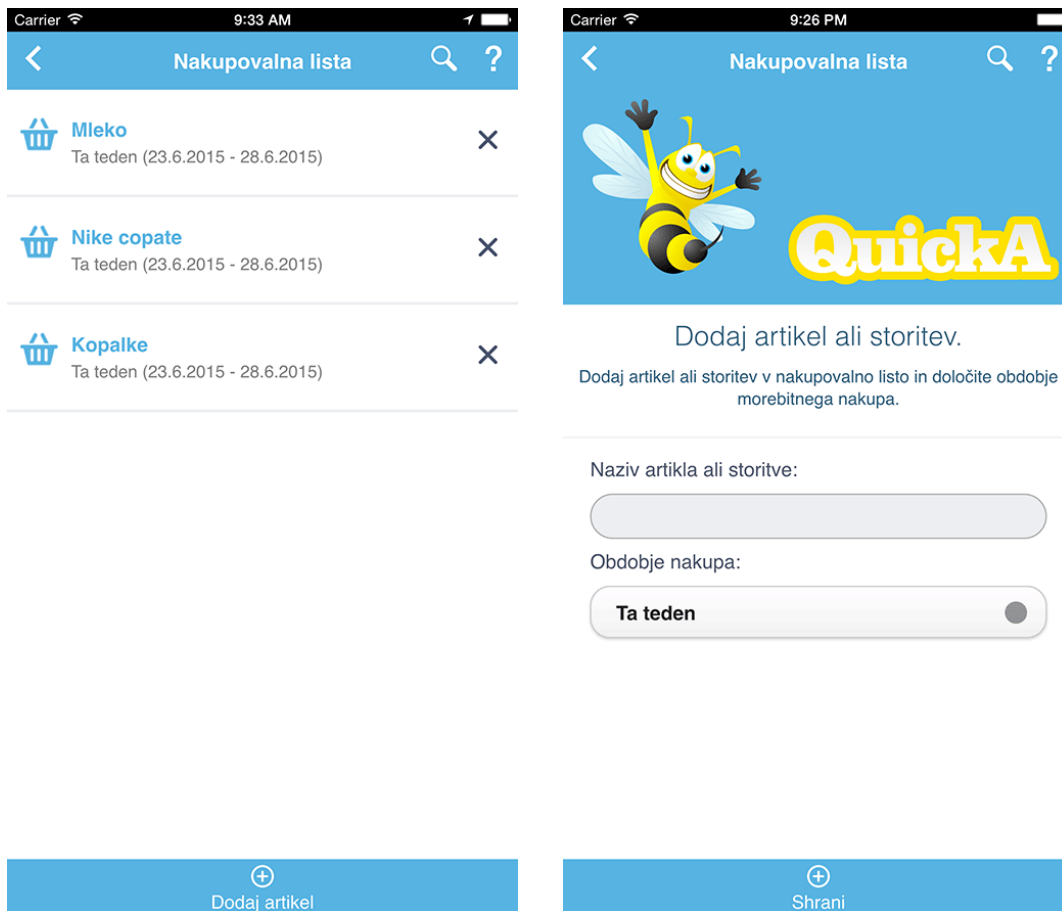
Slika 41: Kategorije produktov in podrobno o produktu

6.6.24 Pametna nakupovalna lista

Pametna nakupovalna lista omogoča uporabniku, da doda v listo produkte ali storitve, ki jih misli kupiti danes ali mogoče prihodnje leto. Uporabnik nato v realnem času pridobiva akcijske ponudbe glede na vsebino nakupovalne liste. Pametna nakupovalna lista se lahko uporablja le kot enkratni klasični nakupovalni listek za v trgovino ali kot lista želja, za katero pridobivamo posebne akcijske ponudbe. Podjetje lahko preko spletnega portala vidi vse dodane produkte v nakupovalni listi in na te produkte poveže prodajne akcije. Če uporabnik želi v naslednjem mesecu kupiti copate Nike, lahko doda ta produkt v nakupovalno listo in vsake toliko časa preveri, katere akcijske ponudbe je pridobil ali si nastavi obvestila. Če uporabnik v nakupovalni listi klikne na produkt, se mu najprej prikaže seznam vseh podjetij ali blagovnih znamk, ki so oddali akcijsko ponudbo za želeni produkt in izbere podjetje, ki mu zaupa. S klikom na izbrano podjetje ali blagovno znamko lahko pridobi različne personalizirane akcijske ponudbe. Uporabnik lahko preko gumba Izbriši odstrani produkt iz nakupovalne liste.

6.6.25 Dodajanje v nakupovalno listo

Pametna nakupovalna lista omogoča uporabniku, da doda v listo produkte ali storitve, ki jih misli kupiti danes ali mogoče prihodnje leto in nato v realnem času pridobiva akcijske ponudbe. S klikom na gumb Dodaj produkt v nakupovalni listi se uporabniku odpre obrazec za dodajanje produkta ali storitve. Uporabnik v obrazec vnese naziv produkta ali storitve ter vnese obdobje nakupa: danes, jutri, ta teden, naslednji mesec, ta mesec, naslednji mesec, v naslednje pol leta, letos, naslednje leto. Glede na obdobje nakupa se produkti, ki imajo bližje konec obdobja nakupa, prikažejo višje v seznamu v nakupovalni listi.



Slika 42: Nakupovalna lista in dodaj produkte v nakupovalno listo

6.6.26 Pomočnik čarovnik

Pomočnik čarovnik od uporabnika pridobiva informacije o njegovih navadah, željah, potrebah ter druge demografske podatke, s katerimi lahko izboljšamo personalizacijo. Uporabnik pri prodajnih akcijah ob posredovanju odgovorov v zameno za akcijske ponudbe in točke zvestobe te odgovore posreduje le podjetju, ki je izdelalo prodajno akcijo. Zaradi varovanja osebnih podatkov uporabnik posredovane odgovore deli le s podjetjem, ki mu zaupa.

S pomočjo pomočnika čarovnika uporabnik odgovori na splošna vprašanja, ki so na voljo vsem podjetjem za filtriranje ali personalizacijo. Nekatera izmed splošnih

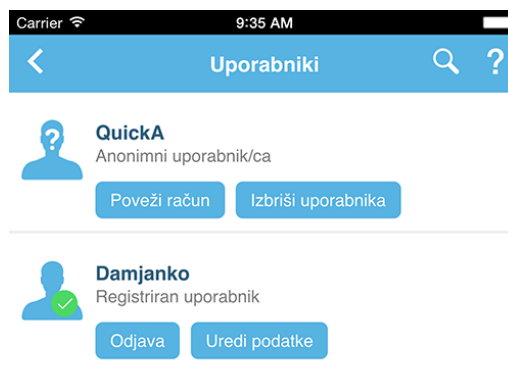
vprašanj so: spol, starost, kraj bivanja, status zaposlitve, povprečna mesečna plača, življenjski slog in nakupne navade. Vprašanja za pomočnika čarovnika pripravi urednik in se izdelajo podobno kot za prodajne akcije, kjer se izdelava odločitveno drevo z vprašanji, le da v tem primeru uporabnik ni nagradjen. Če uporabnik odgovori, da ga zanimajo avtomobili, lahko speljemo odločitveno drevo v dodatna vprašanja, da pridobimo informacije, za katere avtomobile se zanima uporabnik. Če uporabnik na določeno vprašanje ne želi odgovoriti, lahko to vprašanje enostavno preskoči.

6.6.27 Seznam uporabnikov

V seznamu uporabnikov so objavljeni uporabniki, ki na tej napravi uporabljajo našo mobilno aplikacijo. Uporabnik lahko uporablja aplikacijo kot anonimni uporabnik, kar pomeni, da se mu ni potrebno registrirati in prijaviti. Na ta način je zagotovljena večja uporabnost aplikacije, saj nudi možnost uporabe tudi tistim uporabnikom, ki zelo neradi delijo svoje osebne podatke. V primeru, da uporabnik zamenja telefon, lahko s pomočjo posebne identifikacijske kode prenese svoje nastavitve na drugi telefon, kjer se ti podatki združijo v en profil. Uporabnik se lahko v mobilno aplikacijo tudi registrira in prijavi ter si s tem zagotovi enako uporabniško izkušnjo in personalizacijo po vseh napravah glede na skupne podatke. Če uporabnik recimo anonimno uporablja tri različne naprave in se potem prijavi v vse tri naprave z istim uporabniškim računom, se ti podatki združijo in personalizacija je enotna na vseh treh napravah. Uporabnik se lahko iz posamezne naprave tudi odjavi ali uredi svoje podatke: e-naslov, uporabniško ime in geslo.



Pozdravljeni, sem vaš pomočnik in vam bom poskušal na podlagi vaših odgovorov še izboljšati akcijske ponudbe.



Nov uporabnik?

Že imate svoj InfoCity.si račun za enotno prijavo?
Spodaj se lahko prijavite ali registrirate.



Slika 43: Pomočnik čarovnik in seznam uporabnikov

6.6.28 Registracija

Mobilna aplikacija omogoča uporabnikom tudi možnost anonimne uporabe z že dodanim in privzetim anonimnim uporabnikom. Če želi uporabnik svoje nastavitve in podatke uporabljati tudi na drugi napravi (v primeru izgube ali zamenjave naprave), lahko to izvede s prenosom identifikacijske kode na drugo napravo ali poveže anonimni račun z registracijo in prijavo novega uporabnika. Ko se uporabnik prvič registrira in prijavi v napravo, se združijo podatki iz vseh njegovih že uporabljenih naprav in personalizacija se izvaja s pomočjo podatkov, zbranih na vseh napravah. V praksi se lahko zgodi, da je uporabnik v isti prodajni akciji na kateri drugi napravi različno odgovoril na isto anketo. V tem primeru se upošteva zadnji odgovor. Uporabnik ob registraciji v obrazec vpiše svoj uporabniški račun (e-naslov), vzdevek, geslo ter potrdi, da se strinja s splošnimi pogoji uporabe. Uporabnik nato na svoj e-naslov prejme sporočilo za potrditev registracije. Po aktiviranju registracije se lahko uporabnik s svojimi podatki prijavi v aplikacijo.

6.6.29 Prijava

Mobilna aplikacija omogoča uporabnikom, da s pomočjo enotne prijave in istim uporabniškim računom uporabljajo svoje nastavitve, akcijske ponudbe in točke zvestobe na katerikoli napravi. Preko obrazca za prijavo uporabnik vpiše svoj uporabniški račun in geslo ter se prijavi. Če isto napravo uporablja več različnih uporabnikov ali članov družine, lahko z enostavno izbiro in zamenjavo uporabnika v seznamu uporabnikov posameznik pridobi svoje nastavitve, akcijske ponudbe in točke zvestobe. Na ta način je omogočeno enostavno brskanje in nakupovanje s pomočjo družinske tablice, medtem ko na telefonih v večini primerov aplikacijo uporablja en uporabnik.

Registracija novega uporabnika

Ustvarite novi InfoCity uporabniški račun za enotno prijavo. Če se boste registrirali z elektronskim naslovom, boste po e-pošti prejeli navodila za potrditev registracije. Če se boste registrirali anonimno z vzdevkom in brez elektronskega naslova, vnesite še datum rojstva, v primeru izgube gesla.

Uporabniški račun:

Vzdevek:

Geslo:

Ponovite geslo:

Prijava v Quicko

Prijavite se v Quicko in uporabljate svoje akcijske ponudbe in točke zvestobe na katerikoli mobilni napravi ali računalniku.

Uporabniški račun:

Geslo:

Slika 44: Registracija novega uporabnika in prijava

6.7 Testiranje informacijskega in priporočilnega sistema

Pred namestitvijo v produkcijo in med razvojem informacijskega sistema je potrebno izvesti temeljito testiranje. Za vsako razvito funkcijo je bila napisana metoda za testiranje posameznih enot programske opreme, kjer se posebej testira vsako pomembnejšo funkcijo. Po testiranju enot se izvede še sistemsko testiranje, kjer se testira sistem kot celota. To omogoča hitrejše testiranje celotnega sistema ob vsaki objavi razvite kode, kar vodi do kakovostnejše programske kode. Za informacijski sistem smo uvedli pravilo brez napak (angl. Zero Error Policy Management), kar pomeni, da se v vsako funkcijo doda try catch blok, ki zabeleži vsako napako. Uporabil se je tudi sistemski globalni try catch blok na celotnem informacijskem sistemu, ki je beležil napake, na katere nismo pomislili. Na mobilni aplikaciji so se napake shranjevale lokalno in se ob vsakem zagonu ali zaprtju aplikacije prenesle na strežnik, kadar je uporabnik vzpostavil povezavo.

Ob koncu systemskega testiranja smo ob vsaki spremembi ali nadgradnji izvedli še uporabniške teste sprejemljivosti, kjer so uporabniki v živo stestirali vse grafične in uporabniške vmesnike ter vse ostale funkcionalnosti na mobilni aplikaciji in portalu.

6.8 Implementacija in vzdrževanje

Po implementaciji informacijskega sistema se njegova življenjska doba šele začne. Ker lahko med delovanjem pride do nepričakovanih napak ali izpadov, je potrebno stalno preverjanje, testiranje in popravljanje informacijskega sistema. Informacijski sistem je bil razvit tako, da se je vsa poslovna logika izvajala v oblaku Azure, saj je bil informacijski sistem razvit s programskim jezikom C# in ASP.NET, zato je bil Microsoftov oblak najboljša rešitev. Mobilno aplikacijo smo objavili v trgovinah mobilnih aplikacij Apple Store in Google Play. Za vsako od teh trgovin je bilo najprej potrebno pridobiti certifikate za razvijalce in nato smo aplikacije objavili v trgovini. V trgovini Google Play je zaradi avtomatskega testiranja in preverjanja aplikacije bila objavljena še isti dan, pri Apple Store pa je prvo preverjanje trajalo 10 dni.

Z objavo aplikacije je bil to komaj prvi korak v življenjskem ciklu informacijskega sistema, saj je za uspešnost potrebno pridobiti aktivne uporabnike in traction, kar je najtežji del.

7 Analiza odločitvenega in priporočilnega modela ter praktična uporaba

Pri analizi in razvoju informacijskega in priporočilnega sistema smo postavili hipotezo, da bomo lahko z uporabo kvalitetnih podatkov (uporabnikove želje, potrebe, pretekle izkušnje in prihodnji nakupi) uporabniku ponudili bolj personalizirane akcijske ponudbe. S personalizacijo bomo povečali konverzijo CTR (angl. click to rate) med ogledi akcijskih ponudb in odgovori oziroma izvedbo prodajnih akcij.

Prednost našega informacijskega sistema je v tem, da lahko vsako podjetje glede na svoje potrebe izdela poljubne prodajne akcije, kjer sestavi različne večnivojske module glede na svoje komunikacijske, marketinške, prodajne ali poslovne cilje. Podjetje lahko tako preko informacijskega sistema pospešuje prodajo in v realnem času izvaja tržne raziskave ali pridobiva pomembne informacije, ki so ključne za poslovanje podjetja. Unikatna prednost našega informacijskega in priporočilnega sistema je v tem, da lahko podjetje uporabnika pelje in vodi čez prodajni proces z jasno definiranim odločitvenim nakupnim procesom. Pri oglaševalskem sistemu Googlu Adwords lahko nastavimo oglaševalsko akcijo, kjer določimo ključne besede, pri katerih se pokaže določen oglas. Če uporabnik klikne na oglas, ga preusmerijo na spletno stran trgovca, kjer si uporabnik lahko ogleda in kupi produkt. Če spletno stran povežemo še z Google Analytics, lahko pridobimo dodatne informacije preko podrobnejše analitike in izvedbe ciljev, ki smo jih nastavili za spletno trgovino. Na ta način lahko povežemo košarico in oglaševalsko akcijo ter pridobimo informacije, ali je uporabnik kupil produkt ali ne. Žal pa preko tega sistema ne dobimo pomembnih informacij, zakaj je uporabnik kupil produkt, katere produkte ima najraje, katerih produktov ne mara, kaj želi kupiti prihodnje leto in podobno. Naš informacijski sistem ima to prednost, da ob pospeševanju prodaje od uporabnika pridobiva še veliko drugih podatkov, ki so zelo pomembni za poslovanje, odločanje in personalizacijo.

Na področju turizma lahko podjetje preko našega informacijskega sistema sestavi prodajno akcijo:

- Uporabnik se sprehaja po Ljubljani in gre mimo Kompasove poslovalnice. Zunaj je sončno in minimalno 33 stopinj Celzija, mesec julij. QuickA mu ponudi akcijsko ponudbo s 25% popustom za dopust v Turčiji.
- Če uporabnik unovči kupon in kupi potovanje v Turčijo, lahko preko integracije s trgovcem, in sicer preko posebne hash kode #TurcijaPotovanje ali preko lokacijskih storitev, aplikacija zazna, da je uporabnik v Turčiji in ga lepo pozdravi ob prihodu v Turčijo.
- Naslednji dan QuickA uporabnika vpraša, ali je zadovoljen z namestitvijo v hotelu.
- Če uporabnik z namestitvijo ni zadovoljen, ga QuickA povabi, da objavi video posnetek ali fotografijo hotelske sobe in nam v realnem času sporoči, zakaj ni zadovoljen. S tem lahko že na samem izletu v realnem času uredimo vse težave in zmanjšamo stroške s kasnejšimi reklamacijami.
- Naslednji dan QuickA uporabnikom ponudi akcijsko ponudbo za večerjo pri lokalnih gostincih. Tisti uporabniki, ki so vegetarijanci, dobijo različno ponudbo kot tisti, ki jedo meso in ribe.
- Ko se uporabnik vrne s potovanja, ga QuickA zazna in povpraša, kako bi ocenil potovanje in izkušnjo ter mu v zameno za odgovor ponudi še dodatna dva dni

počitka v toplicah čez 14 dni. Na ta način lahko izvajamo up-sell in cross-sell produktov in storitev ter povečujemo in pospešujemo prodajo.

Naš informacijski sistem po funkcionalnostih in namenu ni čisto primerljiv z Googlovim sofisticiranim oglaševalskim sistemom Adwords, ki ima zelo široko mrežo ponudnikov in uporabnikov. Vendar smo lahko naredili primerjavo med izvedeno oglaševalsko akcijo za Galerijo sloART, ki je se tri mesece izvajala na Google Adwords in v našem informacijskem in priporočilnem sistemu. Podatke o CTR, ki smo jih lahko realno primerjali za določeno oglaševalsko akcijo med tema dvema sistemoma, so v prid našemu informacijskemu sistemu, saj je bil splošni CTR skoraj osemkrat večji kot v Google Adwords, in sicer 1,89% za iskanje, 0,43% za prikazno omrežje proti 14,2% v našem priporočilnem sistemu. Ta razlika v korist našega informacijskega sistema nastane predvsem zaradi boljših podatkov, boljše personalizacije in zaradi tega, ker je QuickA namenska aplikacija za nakupovanje, medtem ko Google Adwords lahko prikazuje oglase tudi, kadar ljudje iščejo informacije za službo, seminarsko nalogo, učenje za izpit ali so pač naključno iskali določene informacije s kakšnim drugim namenom. Delno lahko to razliko argumentiramo s tem, da je aplikacija še nova in zanimiva ter ima trenutno v sistemu le manjše število ponudnikov, zato lahko uporabniki brskajo po aplikaciji in preverjajo akcijske ponudbe od vseh ponudnikov. Na daljši rok, ko bo ponudnikov več, bo uporabnik imel večjo izbiro, vendar bomo to informacijsko zasičenost kasneje kompenzirali z več pridobljenimi podatki o uporabniku in na ta način bolje personalizirali akcijske ponudbe.

Če pogledamo rezultate in poročila preko oglaševalskega sistema Google Adwords, smo po dveh mesecih oglaševanja dobili le statistiko oglaševanja in nekaj preusmerjenih uporabnikov na spletno stran, medtem ko smo preko našega informacijskega sistema pridobili podatke, kateri uporabniki se zanimajo za umetnost, kateri avtorji jih zanimajo, katere slike so jim najbolj všeč in še več drugih pomembnih podatkov. S pomočjo pomočnika čarovnika smo pridobili podatke, kot so starost, spol in mesečne prihodke za posamezne uporabnike. Na podlagi teh podatkov lahko naslednjič sestavimo novo prodajno akcijo, kjer cenejše in mlajše umetnike ponujamo mlajši generaciji, ki ne zasluži veliko, in drage impresioniste starejšim moškim z večjimi zaslužki in ljudem, ki so označili, da jih zanima vrhunska umetnost. Glede na vse pridobljene podatke in izvedene analize menimo, da je naš informacijski sistem boljši pri personaliziranem marketingu in prodaji 1:1, vendar ob pogoju, da bomo pridobili zadostno število aktivnih uporabnikov in ponudnikov.

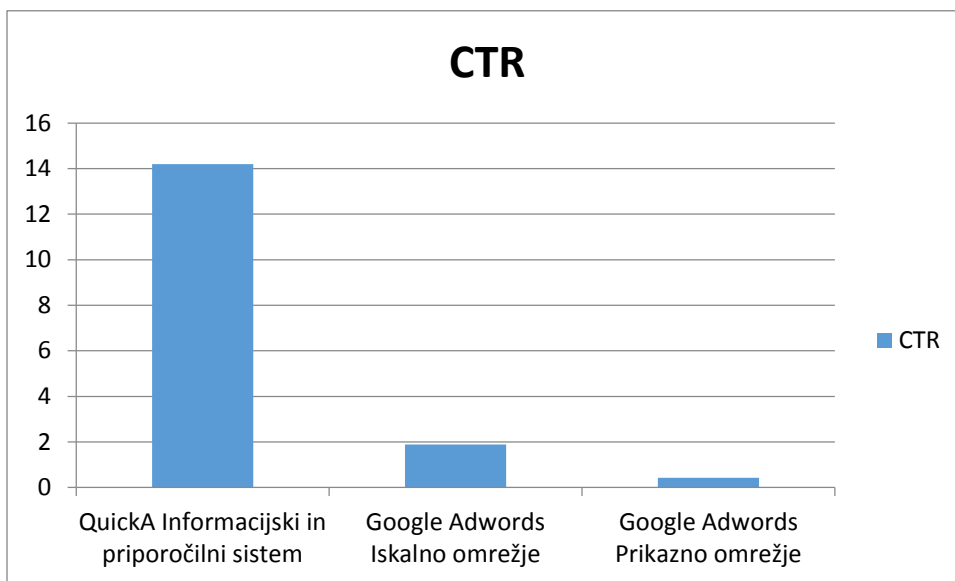
Na podlagi izdelanega in preizkušenega priporočilnega sistema sklepamo, da je za našo rešitev najprimernejša uporaba hibridnih priporočilnih tehnik, kjer se glede na različne situacije uporabita metoda filtriranja CF ali CB v kombinaciji z ostalimi odločitvenimi pravili in pogoji.

Skupine oglasov		Nastavitve	Oglasi	Ključne besede	Ciljne skupine	Razširitev oglasa	Mere	
Vse omogočene skupine oglasov		Segmentiraj	Filter	Stolpci				Išči skupine oglasov
+ SKUPINA OGLASOV		Uredi	Podrobnosti	Strategija ponudb	Samodejno	Oznake		
<input type="checkbox"/>	<input checked="" type="radio"/>	Skupina oglasov	Stanje	Privzet najvišji CPC	Kliki	Prik.	CTR	Povpr. CPC
<input type="checkbox"/>	<input checked="" type="radio"/>	Galerija	Primerna	0,25 € <input checked="" type="checkbox"/>	1.640	86.721	1,89%	0,18 €
Skupaj – vse omogočene skupine oglasov					1.640	86.721	1,89%	0,18 €
Skupaj – iskalno omrežje					1.640	86.721	1,89%	0,18 €

Slika 45: Statistika Google Adwords analitike za iskalno omrežje

Skupine oglasov		Nastavitve	Oglasi	Razširitev oglasa	Mere	Prikazno omrežje		
Vse omogočene skupine oglasov		Segmentiraj	Filter	Stolpci		Išči skupine oglasov		
+ SKUPINA OGLASOV		Uredi	Podrobnosti	Strategija ponudb	Samodejno	Oznake		
<input type="checkbox"/>	<input checked="" type="radio"/>	Skupina oglasov	Stanje	Privzet najvišji CPC	Kliki	Prik.	CTR	Povpr. CPC
<input type="checkbox"/>	<input checked="" type="radio"/>	Retargeting sloART	Oglaševalska akcija začasno zaustavljena	0,35 € <input checked="" type="checkbox"/>	2.031	470.137	0,43%	0,17 €
Skupaj – vse omogočene skupine oglasov					2.031	470.137	0,43%	0,17 €
Skupaj – prikazno omrežje					2.031	470.137	0,43%	0,17 €

Slika 46: Statistika Google Adwords analitike za prikazno omrežje



Slika 47: Primerjava metrik CTR med QuickA in Google Adwords

8 Zaključek

Uporabniki se danes v nakupovalnem procesu soočajo z veliko količino informacij ter široko ponudbo produktov in storitev, kar kupcu onemogoča racionalno odločitev glede nakupa tistih produktov in storitev, ki jih ta dejansko potrebuje v določenem času in kraju, upoštevajoč njegove želje, interese in potrebe.

Z definiranjem in potrditvijo problema pri uporabnikih smo se lotili analize, načrtovanja, razvoja, testiranja in implementacije informacijskega in priporočilnega sistema za personalizacijo prodaje.

Informacijski sistem deluje na poslovnem modelu, da uporabniku za posredovanje pomembnih povratnih informacij v zameno ponudimo akcijske ponudbe ali točke zvestobe. Pomanjkanje kvalitetnih informacij o kupcih, njihovih navadah, prihodnjih nakupih in preteklih izkušnjah je eden od ključnih problemov, da podjetja ne morejo izvajati učinkovite personalizacije. Zato tudi v realnem času nimajo vseh odgovorov na pomembna vprašanja, ki se tičejo marketinga, prodaje in poslovanja podjetja.

V magistrski nalogi sem raziskal in predelal številne strokovne članke s področja priporočilnih sistemov, odločitvenih modelov, sistemov Big Data, interneta stvari in personalizacije v prodajnem procesu. Nekatere dobre prakse in modele za skupinsko filtriranje smo uporabili tudi v našem informacijskem sistemu, ki združuje raznorazne tehnologije in metode za pridobivanje podatkov in personalizacijo. Pri načrtovanju in razvoju informacijskega sistema so se kot ključne izkazale več kot 15-letne izkušnje s področja razvoja informacijskih sistemov in spletnih trgovin za največje slovenske trgovce ter izkušnje s področja digitalnega marketinga, prodaje in tržnih raziskav.

S pomočjo priporočilnih in odločitvenih sistemov ter obdelave velike količine pametnih podatkov lahko kupcu ponudimo personalizirane produkte in storitve ter s tem pospešujemo in povečujemo prodajo, na drugi strani pa izboljšujemo uporabniško ter nakupovalno izkušnjo. Zaradi narave mobilnih naprav lahko danes od uporabnikov pridobimo kontekstualne informacije, njihove lastnosti in druge pomembne informacije, ki jih uporabimo v priporočilnih sistemih [24].

E-trgovanje je postalo pomemben poslovni model v 21. stoletju in ima pomemben vpliv na družbo, gospodarstvo, življenje in kulturo. Velika trgovska podjetja in tudi vse ostale gospodarske družbe, ki bodo hotele preživeti v 21. stoletju, bodo morale prilagoditi svoje poslovanje novim trendom ter poslovati globalno. Uporaba personalizacije in komunikacije s kupcem ena na ena s pomočjo priporočilnih sistemov je ena od ključnih razvojnih prioritiet za vsako podjetje.

Razvoj tehnologij za personalizacijo produktov in storitev se s pomočjo računalništva v oblaku in velikega števila raznoraznih naprav, ki producirajo veliko količino strukturiranih in nestrukturiranih podatkov, danes razvija zelo hitro. V ospredje vedno bolj prihajajo strojno učenje, umetna inteligenca, virtualna resničnost, droni, zato se bo način, kako ljudje kupujejo, v naslednjih desetih letih zelo spremenil. Podjetja, ki ne bodo šla v korak s časom in se digitalno preobrazila, ne bodo uspela in preživela na trgu.

S pomočjo našega informacijskega sistema, ki je bil dvakrat nominiran za Najpodjetniško idejo s strani časnika Finance in bil sprejet kot top inovacija na Forum inovacij, bodo lahko podjetja pridobila pomembne informacije od svojih uporabnikov. Te podatke bodo lahko integrirali s svojimi transakcijskimi podatki in na ta način pridobili 360-stopinjski pogled na kupca, kar jim lahko omogoča boljšo in učinkovitejšo personalizacijo, s katero pospešujejo in povečujejo prodajo, ter izboljšujejo uporabniško in nakupovalno izkušnjo ter boljšo uporabniško podporo.

Seznam slik

Slika 1: Metodologija HCA za predstavitev problema [5]	16
Slika 2: Primer hibridnega priporočilnega sistema.....	18
Slika 3: Faze priporočilnega procesa [11]	23
Slika 4: Priporočeno ogrodje za umetno imunski priporočilni sistem.....	28
Slika 5: Klasifikacija produktov glede na nakupno vedenje uporabnika [53].....	33
Slika 6: Prikaz procesa odločanja v sistemih za podporo odločanju	37
Slika 7: Proces izvlečenja informacij in vpogledov iz Big Data [3].....	50
Slika 8: Marketinški miks analitičnih tehnik za upravljanje podatkov Big Data [47]...	51
Slika 9: Arhitektura IoT [10]	54
Slika 10: Horizontalna predstavitev aplikacij IoT [10]	54
Slika 11: Ontologija uporabniškega profila z uporabniškimi interesi [2].....	67
Slika 12: Stopnja zaskrbljenosti uporabnikov glede zasebnosti in upravljanja z osebni podatki [2]	69
Slika 13: Raziskava podjetja RetailMeNot glede uporabe posebnih promocij	73
Slika 14: Raziskava podjetja RetailMeNot o izvedbi nakupa zaradi posebnih promocij	73
Slika 15: Graf ocene prihodkov, marže in stroškov v poslovne modelu za leto 2015 ..	78
Slika 16: Prikaz podatkovnega modela za prodajne akcije	81
Slika 17: Spletni obrazec za registracijo podjetja.....	83
Slika 18: Spletna stran za urejanje podatkov in predstavitev podjetja	84
Slika 19: Spletna stran seznam akcijskih ponudb.....	86
Slika 20: Spletna stran seznam mojih produktov	87
Slika 21: Spletna stran seznam mojih programov zvestobe	88
Slika 22: Spletna stran seznam mojih prodajnih akcij.....	89
Slika 23: Obrazec oddaj prodajno akcijo.....	90
Slika 24: Spletna stran filtri prodajne akcije.....	91
Slika 25: Spletna stran oddaj filter za ključne besede	92
Slika 26: Spletna stran moduli prodajne akcije	95
Slika 27: Spletna stran oddajte modul prodajne akcije – sporočilo.....	95
Slika 28: Spletna stran oddajte modul prodajne akcije – anketa	96
Slika 29: Spletna stran statistike prodajnih akcij.....	97
Slika 30: Splash screen in domača stran mobilne aplikacije QuickA	98
Slika 31: Priljubljena in priporočena podjetja ter seznam kategorij podjetij.....	100
Slika 32: Priljubljena iskanja in prodajni modul »Sporočilo«.....	101
Slika 33: Prodajni modul »Sporočilo s sliko« in »Galerija«	104
Slika 34: Prodajni modul »Anketa« in »Kviz«.....	106
Slika 35: Prodajni modul »Vprašanje« in »Video vsebina«.....	107
Slika 36: Prodajni modul »Posnemite fotografijo« in »Posnemite video«.....	109
Slika 37: Prodajni modul »Izberite produkt« in »Ocenite produkt«.....	110
Slika 38: Prejeli ste akcijsko ponudbo in obrazec za vpis razloga »Ponudba me ne zanima«.....	112
Slika 39: Prejeli ste točke zvestobe in modul za zamenjavo točk zvestobe za posebno akcijsko ponudbo.....	113
Slika 40: Prenos točk zvestobe na kartico zvestobe in seznam produktov.....	114
Slika 41: Kategorije produktov in podrobno o produktu.....	115
Slika 42: Nakupovalna lista in dodaj produkte v nakupovalno listo	116
Slika 43: Pomočnik čarovnik in seznam uporabnikov	118

Slika 44: Registracija novega uporabnika in prijava	119
Slika 45: Statistika Google Adwords analitike za iskalno omrežje	123
Slika 46: Statistika Google Adwords analitike za prikazno omrežje	123
Slika 47: Primerjava metrik CTR med QuickA in Google Adwords	124

Seznam enačb

Enačba 1: Formula za Pearsonovo korelacijo [11]	11
Enačba 2: Formula za kosinusno podobnost [11]	11
Enačba 3: Formula za izračun srednje absolutne napake MAE	25
Enačba 4: Formula za izračun zgornje srednje kvadratne napake RMSE	25
Enačba 5: Formula za izračun točnosti in odpoklica	25
Enačba 6: Formula za izračun F-meritve	25

Literatura in viri

1. Abdallah Mohamed, "A decision support model for long-term course planning", Canada: Elsevier, *Decision Support Systems*, št. 74, str. 33–45, 2015
2. Ahmad Hawalah, Maria Fasli, "Dynamic user profiles for web personalisation", UK: Elsevier, *Expert Systems with Applications*, št. 42, str. 2547–2569, 2015
3. Amir Gandomi, Murtaza Haider, "Beyond the hype: Big data concepts, methods, and analytics", Canada: Elsevier, *International Journal of Information Management*, št. 35, 137–144, 2015
4. Boris Lublinsky, Kevin T. Smith, Alexey Yakubovich, "Professional Hadoop Solutions", USA: John Wiley & Sons, 2013
5. Chen-Shu Wang, Heng-Li Yang, "A recommender mechanism based on case-based reasoning", Taiwan: Elsevier, *Expert Systems with Applications*, št. 39, str. 4335–4343, 2012
6. ChienHsing Wua, Shu-Chen Kao, Chuan-Chun Wu, Stan Huang, "Location-aware service applied to mobile short message advertising: Design, development, and evaluation", Taiwan: Elsevier, *Information Processing and Management*, št. 51, 625–642, 2015
7. Cong Li, "When does web based personalization really work? The distinction between actual personalization and perceived personalization", USA: Elsevier, *Computers in Human Behavior*, št. 54, str. 25–33, 2016
8. Daniel J. Power, Ramesh Sharda, "Model-driven decision support systems: Concepts and research directions", USA: Elsevier, *Decision Support Systems*, št. 43, str. 1044–1061, 2007
9. David Arnott, Graham Pervan, "Eight key issues for the decision support systems discipline", Australia: Elsevier, *Decision Support Systems*, št. 44, str. 657–672, 2008
10. Eleonora Borgia, "The Internet of Things vision: Key features, applications and open issues", Italy: Elsevier, *Computer Communications*, št. 54, 1–31, 2014
11. F.O. Isinkaye, Y.O. Folajimi, B.A. Ojokoh, "Recommendation systems: Principles, methods and evaluation", Cayro, *Egyptian Informatics Journal*, junij 2015
12. Foster Provost, Tom Fawcett, "Data Science for Business", USA: O'Reilly, 2013
13. Hemant K. Bhargava, Daniel J. Power, Daewon Sun, "Progress in Web-based decision support technologies", USA: Elsevier, *Decision Support Systems*, št. 43, str. 1083–1095, 2007
14. Heng Xu, Xin (Robert) Luo, John M. Carroll, Mary Beth Rosson, "The personalization privacy paradox: An exploratory study of decision making process for location-aware marketing", USA: Elsevier, *Decision Support Systems*, št. 51, 42–52, 2011
15. Heung-Nam Kim, Inay Ha, Kee-Sung Lee, Geun-Sik Jo, Abdulmotaleb El-Saddik, "Collaborative user modeling for enhanced content filtering in recommender systems", Canada: Elsevier, *Decision Support Systems*, št. 51, str. 772–781, 2011
16. In Lee, Kyoochun Lee, "The Internet of Things (IoT): Applications, investments, and challenges for enterprises", USA: Elsevier, *Business Horizons*, št. 58, str. 431–440, 2015
17. J. Bobadilla, F. Ortega, A. Hernando, A. Gutiérrez, "Recommender systems survey", Spain: Elsevier, *Knowledge-Based Systems*, št. 46, str. 109–132, 2013
18. J.P. Shim, Merrill Warkentin, James F. Courtney, Daniel J. Power, "Past, present, and future of decision support technology", USA: Elsevier, *Decision Support Systems*, št. 33, str. 111–126, 2002
19. Jie Lu, Dianshuang Wu, Mingsong Mao, Wei Wang, Guangquan Zhang, "Recommender system application developments: A survey", Australia: Elsevier, *Decision Support Systems*, št. 74, str. 12–23, 2015

20. Jozef Glovaa, Tomáš Sabola, Viliam Vajdaa, "Business Models for the Internet of Things Environment", Slovak Republic: Elsevier, Procedia Economics and Finance, št. 15, 1122–1129, 2014
21. Judith Masthoff, "Group modeling: Selecting a sequence of television items to suit a group of viewers", Netherlands: Kluwer, User Modeling and User-adapted Interaction, št. 14, str. 37–85, 2004
22. Judith Masthoff, "Modeling a group of television viewers", UK: Faculty of Information Technology Brighton, User Modeling 2003: 9th International Conference, str. 34–42, 2002
23. Jure Leskovec, Anand Rajaraman, Jeffrey D. Ullman, "Mining of Massive Datasets", Stanford University, 2014
24. Kai Li, Timon C. Du, "Building a targeted mobile advertising system for location-based services", China: Elsevier, Decision Support Systems, št. 54, str. 1–8, 2012
25. Karthik Kambatla, Giorgos Kollias, Vipin Kumar, Ananth Grama, "Trends in Big Data analytics", USA: Elsevier, Journal of Parallel and Distributed Computing, št. 74, str. 2561–2573, 2014
26. Kenneth C. Laudon, Carol Guercio Traver, "E-commerce 2014", UK: Pearson Education Limited, 2014
27. Kibeom Lee, Kyogu Lee, "Escaping your comfort zone: A graph-based recommender system for finding novel recommendations among relevant items", Republic of Korea: Elsevier, Expert Systems with Applications, št. 42, str. 4851–4858, 2015
28. Kwiseok Kwon, Cookhwan Kim, "How to design personalization in a context of customer retention: Who personalizes what and to what extent?", Republic of Korea: Elsevier, Electronic Commerce Research and Applications, št. 11, str. 101–116, 2012
29. Lun-ping Hung, "A personalized recommendation system based on product taxonomy for one-to-one marketing online", Taiwan: Elsevier, Expert Systems with Applications, št. 29, str. 383–392, 2005
30. Luo Ya, "The Comparison of Personalization Recommendation for E-Commerce", China: Elsevier, Physics Procedia, št. 25, str. 475–478, 2012
31. Maciej Dabrowski, Thomas Acton, "The performance of recommender systems in online shopping: A user-centric study", Ireland: Elsevier, Expert Systems with Applications, št. 40, 5551–5562, 2013
32. Martijn Kagie, Michiel van Wezel, Patrick J.F. Groenen, "A graphical shopping interface based on product attributes" Netherlands: Elsevier, Decision Support Systems, št. 46, str. 265–276, 2008
33. Martínez-Belén Barragáns, Enrique Costa-Montenegro, Jonathan Juncal-Martínez, "Developing a recommender system in a consumer electronic device", Spain: Elsevier, Expert Systems with Applications, št. 42, 4216–4228, 2015
34. Meng-Hui Chen, Chin-Hung Teng, Pei-Chann Chang, "Applying artificial immune systems to collaborative filtering for movie recommendation", Taiwan: Elsevier, Advanced Engineering Informatics, str. 1–10, 2015
35. Michael Manoochehri, "Data just Right", USA: Pearson, 2014
36. Mohamed Anis Dhuieb, Florent Laroche, Farouk Belkadi, Alain Bernard, "Activity theory based context model: application for enterprise intelligent assistant systems", France: Elsevier, IFAC Papers OnLine, št. 48, str. 834–839, 2015
37. Natsuki Sanoa, Natsumi Machinob, Katsutoshi Yada, Tomomichi Suzukia, "Recommendation system for grocery store considering data sparsity", Japan: Elsevier, Procedia Computer Science, št. 60, 1406–1413, 2015
38. PankajDeep Kaur, Sumedha Aror, "Regression and Endogeneity Bias in Big Marketing Data", India: Elsevier, Procedia Computer Science, št. 70, 41–47, 2015

39. Pankesh Patel, Damien Cassou, "Enabling high-level application development for the Internet of Things", India: Elsevier, The Journal of Systems and Software, št. 103, str. 62–84, 2015
40. Parham Moradi, Sajad Ahmadian, Fardin Akhlaghian, "An effective trust-based recommendation method using a novel graph clustering algorithm", Iran: Elsevier, PhysicaA, št. 436, str. 462–481, 2015
41. Prajyoti Lopes, Bidisha Roy, "Dynamic Recommendation System Using Web Usage Mining for E-commerce Users", India: Elsevier, Procedia Computer Science, št. 45, 60–69, 2015
42. Rajan Gupta, Chaitanya Pathak, "A Machine Learning Framework for Predicting Purchase by online customers based on Dynamic Pricing", India: Elsevier, Procedia Computer Science, št. 36, str. 599–605, 2014
43. Rajhans Mishra, Pradeep Kumar, Bharat Bhasker, "A web recommendation system considering sequential information", India: Elsevier, Decision Support Systems, št. 75, str. 1–10, 2015
44. Robert Sommer, Barbara Sommer, "Behavioral research - Tools and Techniques", USA: Oxford University Press, 2002
45. Robin Burke, "Hybrid Recommender Systems: Survey and Experiments", USA: Kluwer, User Modeling and User-adapted Interaction, št. 12, str. 331–370, 2002
46. Samuel Fosso Wamba, Shahriar Akter, Andrew Edwards, Geoffrey Chopin, "How 'big data' can make big impact: Findings from a systematic review and a longitudinal case study", France: Elsevier, Int. J. Production Economics, št. 165, str. 234–246, 2015
47. Shaokun Fan, Raymond Y.K. Lau, J. Leon Zhao, "Demystifying Big Data Analytics for Business Intelligence Through the Lens of Marketing Mix", USA: Elsevier, Big Data Research, št. 2, str. 28–32, 2015
48. Shuchih Ernest Changa, S. Wesley Changchien, Ru-Hui Huangb, "Assessing users' product-specific knowledge for personalization in electronic commerce", Taiwan: Elsevier, Expert Systems with Applications, št. 30, 682–693, 2006
49. Shuk Ying Ho, "The effects of location personalization on individuals' intention to use mobile services", Australia: Elsevier, Decision Support Systems, št. 53, 802–812, 2012
50. Sunil Erevelles, Nobuyuki Fukawa, Linda Swayne, "Big Data consumer analytics and the transformation of marketing", USA: Elsevier, Journal of Business Research, št. 69, str. 897–904, 2016
51. Yiyang Zhang, Jianxin (Roger) Jiao, "An associative classification-based recommendation system for personalization in B2C e-commerce applications", Singapore: Elsevier, Expert Systems with Applications, št. 33, 357–367, 2007
52. Yong Soo Kim, Bong-Jin Yumb, "Recommender system based on click stream data using association rule mining", Republic of Korea: Elsevier, Expert Systems with Applications, št. 38, str. 13320–13327, 2011
53. Yoon Ho Choa, Jae Kyeong Kimb, Soung Hie Kima, "A personalized recommender system based on web usage mining and decision tree induction", South Korea: Pergamon, Expert Systems with Applications, št. 23, str. 329–342, 2002
54. Yue He, Jinxiu Tan, "Study on SINA micro-blog personalized recommendation based on semantic network", China: Elsevier, Expert Systems with Applications, št. 42, 4797–4804, 2015
55. Yueshen Xu, Jianwei Yin, "Collaborative recommendation with user generated content", China: Elsevier, Engineering Applications of Artificial Intelligence, št. 45, 281–294, 2015
56. Yung-Ming Li, Chun-Te Wu, Cheng-Yang Lai, "A social recommender mechanism for e-commerce: Combining similarity, trust, and relationship", Taiwan: Elsevier, Decision Support Systems, št. 55, str. 740–752, 2013

57. Zhijie Lin, "An empirical investigation of user and system recommendations in e-commerce", China: Elsevier, Decision Support Systems, št. 68, str. 111–124, 2014