ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE

FAKULTA ELEKTROTECHNICKÁ

KATEDRA POČÍTAČŮ

Diplomová práce

Doporučovací systém pro eshop

Bc. Martina Čiefová

Vedoucí práce: Ing. Jan Drchal, Ph.D.

Leden 2018

České vysoké učení technické v Praze
Fakulta elektrotechnická

Katedra počítačů

ZADÁNÍ DIPLOMOVÉ PRÁCE

Student: Čiefová Martina

Studijní program: Otevřená informatika
Obor: Umělá inteligence

Název tématu: Doporučovací systém pro eshop

Pokyny pro vypracování:

1) Nastudujte současné metody doporučování (recommender systems).
2) Seznamte se s daty obchodu Kickz (kickz.com), případně obdobnými daty dostupnými v rámci ACM RecSys Challenge 2017 (2017.recsyschallenge.com).
3) Vyberte vhodný nástroj, případně framework pro doporučování.
4) Navrhněte a implementujte doporučovací systém nad vybranou datovou sadou. Zaměřte se zejména na výběr a konstrukci vhodných příznaků. Prozkoumejte možnosti cold start.
5) Důležitou částí práce bude návrh metodologie vyhodnocování kvality a samotné tstování doporučovacího systému. Kvalitu doporučovacího systému vyhodnoťte s použitím dodaných dat minimálně v offline režimu.

Seznam odborné literatury:

[1] Jannach, Dietmar, et al.: ?Recommender systems: an introduction.? Cambridge University Press, 2010.
[2] Schein, Andrew I., et al. "Methods and metrics for cold-start recommendations." Proceedings of the 25th annual international ACM SIGIR conference on Research and development in information retrieval. ACM, 2002.
[3] Dvořák, Lukáš: ?Analytický framework nad interakčními daty z eshopů.? FIT CTU in Prague, master thesis, 2016.

Vedoucí: Ing. Jan Drchal, Ph.D.

Platnost zadání do konce zimního semestru 2018/2019

L.S.

prof. Dr. Michal Pěchouček, MSc.
vedoucí katedry

prof. Ing. Pavel Ripka, CSc.
děkan

V Praze dne 21.7.2017

Poďakovanie

V prvom rade by som sa chcela poďakovať vedúcemu mojej diplomovej práce pánovi Ing. Janovi Drchalovi, Ph.D., za jeho čas, pripomienky, návrhy a odbornú pomoc počas písania práce. Veľká vďaka patrí tvorcom a vývojárom systému Recombee za ich pomoc a konzultácie počas experimentov vykonaných v rámci tejto práce, ďalej Ing. Josefovi Dvořákovi za ochotu prispôsobiť jeho vyhodnocovací systém pre potreby mojej práce, e-shopu Kickz za ponúknuté dáta a kolegovi Jakubovi Melezínkovi za technické rady a podporu. V neposlednom rade sa chcem poďakovať mojej rodine za podporu počas celého môjho štúdia a písania tejto práce.

Čestné vyhlásenie

Vyhlasujem, že som predloženú prácu vypracovala samostatne a že som uviedla všetky použité informačné zdroje v súlade s Metodickým pokynem o etické přípravě vysokoškolských závěrečných prací.
Beriem na vedomie, že sa na moju prácu vzťahujú práva a povinnosti vyplývajúce zo zákona č. 121/2000 Sb., autorského zákona, v znení neskorších predpisov.

Praha, 9. januára 2018 .....

Abstrakt

Cieľom tejto diplomovej práce je vykonať dôležité kroky pred uvedením odporúčacieho systému do prevádzky internetového obchodu. Práca obsahuje analýzu ponúknutých dát od e-shopu Kickz a návrh vhodnej metodológie vyhodnocovania zvoleného odporúčacieho systému. Súčasťou práce je aj teoretický úvod do problematiky odporúčacích systémov s popisom používaných odporúčacích metód. Ponúka prehľad súčasných poskytovateľov odporúčacích systémov, ako aj popis konkrétnych riešení danej problematiky vo vybraných e-shopoch. Okrem toho obsahuje aj prehľad využívaných vyhodnocovacích prístupov. Dôležitou časťou tejto práce je analýza výsledkov získaných pri navrhnutom postupe vyhodnocovania a výber najvhodnejšieho odporúčacieho modelu pre skúmané dáta.

Kľúčové slová odporúčacie systémy, vyhodnocovanie odporúčacích systémov, Recombee, cold start problém, recall-coverage multiobjektívne vyhodnocovanie

Abstract

The aim of this diploma thesis is to take important steps before the implementation of a recommendation system to an e-shop. The thesis is based on the data provided by Kickz e-shop and it aims to deliver an advisable evaluation approach for a chosen recommendation system. A theoretical introduction to the recommendation systems, as part of the diploma thesis, contains the descriptions of used recommendation methods and evaluation approaches. This thesis provides an overview of contemporary recommendation system providers and offers a description of solutions applied in chosen e-shops. The last parts of the thesis analyze achieved evaluation results and focus on the selection of a suitable recommendation model for the researched data.

Keywords recommendation systems, recommendation system evaluation, Recombee, Cold Start Problem, Recall-Coverage Multi-Objective Evaluation

Obsah

1 Úvod 1

2 Teoretický úvod do problematiky odporúčacích systémov 3

2.1 Formálna definícia odporúčacích systémov a popis domén 3

2.1.1 Vymedzenie domén a zdrojov dát odporúčacích systémov 3

2.1.2 Podnet na vznik odporúčacích systémov 6

2.1.3 Popis jednotlivých komponentov odporúčacích systémov 7

2.2 Základné koncepty odporúčacích systémov 9

2.2.1 Kolaboratívne odporúčacie systémy 9

2.2.2 Obsahovo orientované odporúčacie systémy 14

2.2.3 Demografické odporúčacie systémy 15

2.2.4 Znalostne orientované odporúčacie systémy 16

2.2.5 Komunitne orientované odporúčacie systémy 17

2.2.6 Hybridné odporúčacie systémy 17

2.3 Cold start problém 21

2.3.1 Problém nového objektu 21

2.3.2 Problém nového používateľa 21

2.3.3 Prehľad niektorých riešení cold start problému 21

3 Príklady použitia odporúčacích systémov 23

3.1 Pozitívny vplyv odporúčacích systémov na oblasť e-komerčného predaja 23

3.2 Konkrétne príklady použitia odporúčacích systémov vybranými e-shopmi 24

3.2.1 Amazon.com 24

3.2.2 eBay 26

3.2.3 Netflix 27

3.2.4 Mendeley Suggest 29

3.3 Príklady poskytovateľov odporúčacích systémov 31

3.3.1 Fact-Finder 31

3.3.2 econda 31

3.3.3 Yoochoose 32

4 Návrh odporúčacieho systému 34

4.1 Určenie presnosti odporúčacieho systému 34

4.2 Výber prístupu používaného odporúčacím systémom 34

4.3 Nastavenie parametrov systému 35

5 Vyhodnotenie odporúčacieho systému 36

5.1 Online vyhodnocovanie 36

5.2 Offline vyhodnocovanie 37
5.2.1 Metriky na vyhodnotenie odporúčacieho systému na základe historických dát 38
5.2.2 Recall-coverage multiobjektívne vyhodnocovanie 39
6 Analýza problému a návrh metodológie riešenia 41
6.1 Analýza dát z e-shopu Kickz 41
6.2 Popis vybraného odporúčacieho systému 43
6.3 Popis vybraného vyhodnocovacieho systému 44
6.4 Návrh metodológie vyhodnocovania 45
7 Experimenty 48
7.1 Výber atribútov objektov a predspracovanie dát 48
7.2 Export dát do databázy Recombee 49
7.3 Spôsob vytvorenia testovacej vzorky 49
7.4 Výsledky experimentov 51
7.4.1 UserkNN model 51
7.4.2 Ranking Item kNN model 55
7.4.3 Token Item kNN model 57
7.5 Diskusia výsledkov a výber najvhodnejšieho modelu a jeho parametrov 59
8 Záver 61
9 Zoznam použitej literatúry 62
Príloha A Grafy výsledkov vyhodnocovania odporúčacích modelov 66
Príloha B Ukážka odporúčaní pre vybraných používateľov 76
B.1 UserkNN model s parametrami kknn =1171, β = 0.2 76
B.2 Ranking Item kNN model s parametrami kknn = 598, β = 0 81
B.3 Token Item kNN model s parametrami kknn = 8, β = -0.6 nad dátami objektov s atribútmi značka, kategória, pohlavie, materiál, krátky popis 86
Príloha C Obsah priloženého CD 91

Zoznam obrázkov

Obrázok 2.1 Komponenty odporúčacieho systému [6] 8
Obrázok 2.2 Príklad matice preferencií [10] 11
Obrázok 2.3 Príklad vyrátania podobností medzi prvým používateľom a ostatnými používateľmi s využitím kosínusovej podobnosti [10] 11
Obrázok 2.4 Ilustrovanie výsledného odhadu ohodnotenia objektov na základe ohodnotenia objektu podobným používateľom ováhovaným získanou hodnotou podobnosti medzi používateľmi [10] 12
Obrázok 2.5 Príklad vyrátania podobností medzi prvým objektom a ostatnými s využitím kosínusovej podobnosti [10] 12
Obrázok 2.6 Ilustrovanie výsledného odhadu ohodnotenia objektov na základe ohodnotenia pôvodného objektu vybraným používateľom ováhovaným získanou hodnotou podobnosti medzi objektmi [10] 13
Obrázok 2.7 Príklad reprezentácie obsahu objektov 15
Obrázok 2.8 Odporúčací systém ako black box [8] 18
Obrázok 2.9 Schéma monolitického hybridného odporúčacieho systému [8] 19
Obrázok 2.10 Schéma paralelného hybridného odporúčacieho systému [8] 20
Obrázok 2.11 Schéma pipeline hybridného odporúčacieho systému [8] 20
Obrázok 3.1 Príklad odporúčaní vygenerovaných systémom “Customers who Bought” [29] 24
Obrázok 3.2 Príklad „Customer reviews“ na Amazon.com 25
Obrázok 3.3 „*Feedback Profile*” predajcu *grandeagleretail* na ebay.com 26
Obrázok 3.4 Ukážka odporúčaní prezentovaných používateľovi Netflix-u [30] 27
Obrázok 3.5 Odporúčania filmov na Netflix založené na filme pozretým daným používateľom 28
Obrázok 3.6 Odporúčania filmov na Netflix založené na dvoch filmoch pozretých daným používateľom [30] 29
Obrázok 3.7 Náhľad odporúčaní vygenerovaných Mendeley Suggest [32] 30
Obrázok 3.8 Príklad odporúčaní generovaných Fact-finder odporúčacím systémom [33] 32
Obrázok 7.1 Histogram zobrazujúci početnosť používateľov podľa množstva zakúpených produktov úrovne *product color variant* z historických dát 50
Obrázok 7.2 Histogram zobrazujúci početnosť používateľov podľa množstva zakúpených produktov úrovne *product* z historických dát 50
Obrázok 7.3 Graf získaných hodnôt recall a coverage počas vyhodnocovania modelu UserkNN nad dátami s objektmi úrovne *product* s vybalansovanými testovacími dátami 52
Obrázok 7.4 Graf získaných hodnôt recall a coverage počas vyhodnocovania modelu UserkNN nad dátami s objektmi úrovne *product* s testovacou množinou o veľkosti 10 000 vzoriek z pohľadu parametra *kknn* 54

Obrázok 7.5 Graf získaných hodnôt recall a coverage počas vyhodnocovania modelu UserkNN nad dátami s objektmi úrovne *product* s testovacou množinou o veľkosti 10 000 vzoriek z pohľadu parametra *beta* 55
Obrázok 7.6 Graf získaných hodnôt recall a coverage počas vyhodnocovania modelu Ranking Item kNN nad dátami s objektmi úrovne *product* 56
Obrázok A.1 Graf získaných hodnôt recall a coverage počas vyhodnocovania modelu UserkNN nad dátami s objektmi úrovne *product colot variant* 66
Obrázok A.2 Graf získaných hodnôt recall a coverage počas vyhodnocovania modelu UserkNN nad dátami s objektmi úrovne *product* 67
Obrázok A.3 Graf získaných hodnôt recall a coverage počas vyhodnocovania modelu Token Item kNN s kombináciou atribútov objektov značka, kategória, pohlavie, farba, materiál, krátky popis, dlhý popis 68
Obrázok A.4 Graf získaných hodnôt recall a coverage počas vyhodnocovania modelu Token Item kNN s kombináciou atribútov objektov značka, kategória, pohlavie 69
Obrázok A.5 G Graf získaných hodnôt recall a coverage počas vyhodnocovania modelu Token Item kNN s kombináciou atribútov objektov značka, kategória, pohlavie, krátky popis 70
Obrázok A.6 Graf získaných hodnôt recall a coverage počas vyhodnocovania modelu Token Item kNN s kombináciou atribútov objektov značka, kategória, pohlavie, farba .. 71
Obrázok A.7 Graf získaných hodnôt recall a coverage počas vyhodnocovania modelu Token Item kNN s kombináciou atribútov objektov značka, kategória, pohlavie, farba, krátky popis 72
Obrázok A.8 Graf získaných hodnôt recall a coverage počas vyhodnocovania modelu Token Item kNN s kombináciou atribútov objektov značka, kategória, pohlavie, materiál 73
Obrázok A.9 Graf získaných hodnôt recall a coverage počas vyhodnocovania modelu Token Item kNN s kombináciou atribútov objektov značka, kategória, pohlavie, materiál, krátky popis 74
Obrázok A.10 Graf získaných hodnôt recall a coverage počas vyhodnocovania modelu Token Item kNN s kombináciou atribútov objektov značka, kategória, pohlavie, farba, materiál, krátky popis 75

Zoznam tabuliek

Tabuľka 2.1 Rozdelenie odporúčacích systémov podľa kategórie vstupov, ktoré spracúvajú [8] 18
Tabuľka 5.1 Klasifikácia možných výsledkov odporučených objektov používateľovi [1] .. 37
Tabuľka 6.1 Ilustrácia abstrakcie produktu v e-shope Kickz 42
Tabuľka 6.2 Vybrané atribúty jednotlivých úrovní produktov 42
Tabuľka 7.1 Zoznam zvolených atribútov objektov úrovne *product* a ich typov 48
Tabuľka 7.2 Vhodní kandidáti pre UserkNN model 53
Tabuľka 7.3 Vhodní kandidáti pre Ranking Item kNN model 56
Tabuľka 7.4 Zoznam vyhodnotení Token Item kNN modelu 57
Tabuľka 7.5 Parametre modelov maximalizujúcich RChm a získané výsledky recall a coverage počas testov Token Item kNN modelu 57
Tabuľka 7.6 Parametre modelov maximalizujúcich RChm a získané výsledky recall a coverage počas všetkých testov navrhnutého vyhodnocovania 59
Tabuľka B.1 Popis odporúčaní vygenerovaných UserkNN modelom pre používateľa 699251 76
Tabuľka B.2 Popis odporúčaní vygenerovaných UserkNN modelom pre používateľa 497661 77
Tabuľka B.3 Popis odporúčaní vygenerovaných UserkNN modelom pre používateľa 769353 79
Tabuľka B.4 Popis odporúčaní vygenerovaných Ranking Item kNN modelom pre používateľa 699251 81
Tabuľka B.5 Popis odporúčaní vygenerovaných Ranking Item kNN modelom pre používateľa 497661 82
Tabuľka B.6 Popis odporúčaní vygenerovaných Ranking Item kNN modelom pre používateľa 769353 84
Tabuľka B.7 Popis odporúčaní vygenerovaných Token Item kNN modelom pre používateľa 699251 86
Tabuľka B.8 Popis odporúčaní vygenerovaných Token Item kNN modelom pre používateľa 497661 87
Tabuľka B.9 Popis odporúčaní vygenerovaných Token Item kNN modelom pre používateľa 769353 89

1 Úvod

Internetová éra so sebou priniesla rozmach e-shopov, ktoré oproti kamenným predajniam majú možnosť ponúknuť zákazníkom značné množstvo produktov. Táto vymoženosť okrem možnosti rôznorodého výberu so sebou ale prináša aj zahltenie zákazníkov veľkým množstvom informácií. Okrem toho, pribúdajúci počet internetových obchodov predstavuje pre ich prevádzkovateľov rastúcu konkurenciu.

Jedným z riešení týchto problémov predstavuje využitie odporúčacích systémov. Tie jednak utužujú dôveru zákazníka v daný obchod, a takisto mu ponúkajú možnosť objaviť pre neho doteraz neznáme produkty. Na dosiahnutie tohto pozitívneho vplyvu na zákazníka je ale potrebné, aby mu bol odporúčací systém schopný ponúknuť pre neho relevantné odporúčania.

Ďalším významným kritériom systému je, aby bol schopný vytvárať kvalitné odporúčania aj v prípade nových zákazníkov alebo v prípade zavedenia nových produktov do ponuky obchodu. Táto situácia referuje na jav známy pod názvom cold start problém.

Existuje niekoľko odporúčacích metód, ktoré sa používajú na generovanie navrhovaných produktov, no žiaden z nich nie je schopný spoľahlivo pracovať nad všetkými druhmi vstupných dát. Preto je pri návrhu odporúčacieho systému dôležitá podrobná analýza charakteru týchto dát, na základe ktorej je možné následne vylúčiť nevhodné odporúčacie prístupy. Výber vhodného spôsobu vyhodnocovania vybraných odporúčacích modelov zohráva takisto veľkú úlohu, pretože napomáha odhaľovať nedostatky jednotlivých modelov.

Táto práca sa zameriava na analýzu dát a odporúčacích modelov v rámci odporúčacieho systému Recombee za účelom výberu vhodného modelu pre športový internetový obchod Kickz. Na vyhodnocovanie jednotlivých modelov využíva recall-coverage multiobjektívne vyhodnocovanie, a tak isto sa sústreďuje na schopnosť modelu vysporiadať sa s cold start problémom.

Práca je rozdelená na 6 kapitol. Prvá kapitola obsahuje teoretický úvod do problematiky odporúčacích systémov. Sústreďuje sa na vymedzenie domén, popis a definíciu týchto systémov a popis ich jednotlivých častí. Ďalej ponúka prehľad a popis najpoužívanejších metód na generovanie odporúčaní. Záver tejto kapitoly sa venuje javu s názvom cold start problém.

Ďalšia kapitola sa venuje konkrétnym príkladom použitia odporúčacích systémov. Obsahuje prehľad niektorých riešení týchto systémov vo zvolených e-shopoch, a takisto príklady niektorých súčasných prevádzkovateľov odporúčacích systémov s popisom ponúkaných vymožeností.

Kapitoly 4 a 5 vysvetľujú jednotlivé kroky, podľa ktorých by sa malo postupovať pri návrhu odporúčacieho systému, a popisujú metodológie využívané pri vyhodnocovaní odporúčacích systémov.

Zvyšné kapitoly obsahujú analytickú a experimentálnu časť práce, spoločne s vyhodnotením výsledkov vyhodnocovania a návrhom vhodného odporúčacieho

modelu pre dané dáta. Prílohy obsahujú dodatočné grafy výsledkov vyhodnocovania a ukážku odporúčaní vygenerovanými vybranými modelmi.

2 Teoretický úvod do problematiky odporúčacích systémov

Odporúčacie systémy sú v [1] definované ako softwarové nástroje a techniky, ktoré navrhujú používateľovi také objekty, ktoré by mohli byť pre neho užitočné. Súčasťou generovania týchto odporúčaní je snaha o nájdenie rovnováhy vo faktoroch ako novota, stabilita, rozptýlenosť a presnosť jednotlivých odporúčaní [2].

2.1 Formálna definícia odporúčacích systémov a popis domén

Nasledujúca formálna definícia odporúčacích systémov je čerpaná zo zdroja [3].

Majme množinu všetkých používateľov *C* a množinu *S* zahŕňajúcu všetky objekty dostupné na vytvorenie odporúčaní. Veľkosť množiny všetkých objektov *S* môže dosahovať stovky, tisícky a v niektorých prípadoch až milióny objektov, pričom tieto rozmery môže nadobúdať aj priestor množiny používateľov *C*.

Majme funkciu utility *u*, ktorá vyjadruje užitočnosť objektu *s* pre používateľa *c*, a teda

$$u: C \times S \rightarrow R,$$

kde *R* predstavuje úplnú usporiadanú množinu čísel, napríklad množinu kladných prirodzených alebo reálnych čísel z vybraného intervalu.

Potom pre používateľa $c \in C$ chceme vybrať taký objekt $s' \in S$, ktorý maximalizuje zadefinovanú utilitu. Formálne:

$$\forall\, c \in C, \qquad s'_c = \arg\max_{s \in S} u(c, s).$$

Utilita v odporúčacích systémoch obyčajne predstavuje rating alebo ohodnotenie, ktoré vyjadruje, ako veľmi sa daný objekt páči danému používateľovi. Jej hodnota väčšinou nie je definovaná pre celý priestor $C \times S$, ale len pre jeho podmnožinu. Tento fakt predstavuje základný problém v odporúčacích systémoch. Znamená to teda, že je nutné extrapolovať utilitu do celého tohto priestoru, čo môže byť dosiahnuté pomocou:

1. zavedenia heuristiky definujúcej funkciu utility a empiricky validujúcej jej výsledky,
2. odhadu funkcie utility optimalizujúcej určité kritérium (napr. stredná kvadratická chyba[1]).

2.1.1 Vymedzenie domén a zdrojov dát odporúčacích systémov

Odporúčacie systémy spracovávajú informácie a zhromažďujú rôzne druhy dát za účelom vytvorenia odporúčaní. Tieto informácie a dáta sa primárne týkajú objektov, z ktorých systém generuje odporúčania, a z používateľov, ktorým sú následne tieto odporúčania ponúknuté.

[1] Mean Square Error

Odporúčacie systémy vo všeobecnosti využívajú dáta z troch typov domén [1]:

1. objekty,
2. používatelia,
3. transakcie.

Nasledujúce informácie o jednotlivých doménach sú primárne čerpané zo zdroja [1].

2.1.1.1 Objekty

Pojem objekty, prípadne produkty, zahŕňa predmety alebo služby, ktoré odporúčací systém využíva na vytváranie odporúčaní. Objekty môžu byť charakterizované svojou zložitosťou a svojou hodnotou alebo utilitou, pričom táto hodnota môže byť pozitívna, ale aj negatívna. Pozitívna je v prípade, ak je objekt užitočný pre používateľa a negatívna je v situácii, kedy tento objekt nie je užitočný pre používateľa a znamená pre neho zlú voľbu, ak si ho vyberie.

Nadobúdanie objektu pre používateľa zahŕňa určité náklady, ktoré zahŕňajú jednak kognitívnu zložku pri hľadaní objektu používateľom a takisto aj finančnú zložku, ktorú používateľ pri nákupe objektu prípadne zaplatí.

Tieto zložky sa dajú názornejšie popísať na príklade návrhu odporúčacieho systému pre prevádzkovateľa internetových novín, kedy projektant systému musí okrem zložitosti článku, jeho štruktúry a jeho aktuálnosti myslieť aj na to, že aj keď používateľ neplatí za čítanie článkov v daných novinách, stále vynakladá kognitívne náklady spojené s hľadaním a prečítaním si článku.

Ak je nájdený článok relevantný pre používateľa, získanie užitočnej informácie dominuje nad týmito nákladmi. Naopak, ak tento článok nie je relevantný, výsledný zisk pre používateľa nadobúda negatívnu hodnotu.

Pri doménach objektov obsahujúcich finančne náročné objekty (autá, domy, atď.) je dôležitou zložkou pri výbere odporúčaní pre používateľa práve skutočná finančná hodnota objektov.

Podľa zložitosti a hodnoty môžeme objekty rozdeliť do nasledovných skupín:

1. objekty s nízkou hodnotou a zložitosťou – patria sem napríklad knihy, noviny, filmy,
2. objekty s vysokou hodnotou a zložitosťou – patria sem napríklad rôzne druhy elektroniky,
3. najkomplexnejšie objekty vzhľadom na hodnotu a zložitosť – patria sem napríklad finančné investície, cestovanie alebo pracovné pozície.

Rozsah atribútov a príznakov jednotlivých objektov je spravidla podmienený technológiou, ktorú odporúčací systém využíva. Navyše sa systém môže naučiť, ako utilita jednotlivých objektov závisí na výbere jednotlivých príznakov daných objektov.

Na reprezentáciu objektov môžu byť využité rozličné informácie a formy reprezentácie, ktoré môžu predstavovať jednoduchý id kód alebo zložitejšiu formu v podobe množiny atribútov, či konceptu v ontologickej reprezentácii domény.

2.1.1.2 Používatelia

Používatelia alebo zákazníci môžu mať v kontexte odporúčacích systémov rozličné ciele a vlastnosti. Odporúčací systém skúma za účelom vytvorenia odporúčaní určitý

rámec informácii získaných od používateľa, pričom tieto informácie môžu byť štruktúrované rôznymi spôsobmi.

Model alebo profil používateľa predstavuje jeho preferencie a potreby. S využitím tohto pojmu môžu byť odporúčacie systémy chápané ako systémy, ktoré generujú odporúčania pre používateľa prostredníctvom skúmania a vytvárania modelov používateľov.

Výber dát na vytvorenie profilu používateľa je podobne ako pri výbere príznakov objektov (2.1.1.1) ovplyvnený odporúčacou technikou využitou v danom systéme. Napríklad v prípade kolaboratívneho filtrovania (2.2.1) je používateľ modelovaný ako zoznam jeho hodnotení jednotlivých objektov.

Používateľ môže byť ďalej reprezentovaný aj určitými vzorcami príznačnými pre dáta o jeho správaní sa, pričom toto správanie môže zahŕňať prehľadávanie stránok, či hľadanie informácii o žiadaných objektoch a službách. Informácie o používateľoch môžu byť obohatené aj dátami o vzťahu medzi nimi v zmysle úrovne ich dôvery v tento vzájomný vzťah. Tieto dáta môžu byť využité systémom pri výbere odporúčaní pre používateľa na základe preferovaných objektov používateľmi, ktorým daný používateľ dôveruje.

2.1.1.3 Transakcie

Transakcie sú v kontexte odporúčacích systémov chápané ako zaznamenané interakcie medzi používateľom a odporúčacím systémom. Predstavujú v podstate logovacie dáta, záznamy, ktoré v sebe uchovávajú dôležité informácie získané počas interakcie človek-robot a ktoré sú užitočné pre odporúčací algoritmus využívaný daným systémom.

Obsahom takýchto záznamov môže byť napríklad odkaz na objekt, ktorý si používateľ vybral, a popis kontextu (napr. používateľov zámer, požiadavka), v ktorom bolo odporúčanie vygenerované. Ďalej môžu tieto záznamy obsahovať aj dáta o explicitnej spätnej väzbe používateľa na vybraný objekt, ako je napríklad jeho ohodnotenie tohto objektu.

Medzi najpoužívanejšie formy transakcií patria ohodnotenia alebo ratingy, ktoré môžu byť získavané implicitne alebo explicitne. Získavanie explicitných ohodnotení môže predstavovať napríklad požiadanie používateľa o vyjadrenie svojho názoru na objekt v podobe škály ohodnotenia.

Podľa [4] môžu byť ohodnotenia vyjadrené napríklad v jednej z nasledujúcich foriem:

- numerické ohodnotenie (napríklad 1-5 hviezdičiek),
- ordinálne ohodnotenie (napríklad „veľmi súhlasím, súhlasím, neutrálne, nesúhlasím, veľmi nesúhlasím“),
- binárne ohodnotenie, kedy sa používateľ rozhodne, či je nejaký objekt v jeho ponímaní dobrý alebo zlý,
- unárne ohodnotenie, ktoré môže vyjadrovať skutočnosť, že si používateľ pozrel daný objekt alebo si ho kúpil, alebo ho pozitívne ohodnotil.

Používateľovo ohodnotenie môže mať napríklad aj formu tagov, ktoré vyjadrujú jeho asociácie s danými objektmi.

Pri implicitnom získavaní ohodnotení si systém odvodzuje používateľove názory na základe jeho činnosti. Toto odvodenie sa dá ilustrovať scenárom, v ktorom používateľ

v e-shope zadá nejaký výraz do rýchleho vyhľadávania a v zobrazenom zozname objektov odpovedajúcim zadanému výrazu klikne na objekt, ktorý ho zaujal, a o ktorom chce zistiť viac informácií. Z takého používateľovho správania si môže systém odvodiť, že sa používateľ určitým spôsobom zaujíma o vybraný objekt.

Dialógovými systémami sú označované také systémy, ktoré umožňujú interaktívny proces s používateľom a v ktorých sa požiadavky používateľa striedajú s akciami systému. V prípade použitia takýchto systémov je transakčný model komplexnejší. Po poslaní požiadavky na odporúčací systém používateľom môže systém buď vytvoriť zoznam odporúčaní pre tohto používateľa alebo si vyžiadať viac informácií týkajúcich sa používateľových preferencií pre docielenie lepšieho výsledku. Zozbierané odpovede na požiadavky, ktoré počas tohto procesu systém smeruje smerom na používateľa, môže systém využiť pri učení sa modifikácie svojej interakčnej stratégie, ktoré je podmienené výsledkom tohto odporúčacieho procesu.

2.1.2 Podnet na vznik odporúčacích systémov

Myšlienka na vytvorenie odporúčacích systémov má svoje korene v pochopení prirodzenej tendencie človeka spoliehať sa na odporúčania iných ľudí, či už pri každodenných činnostiach, pri výbere knihy na čítanie alebo pri výbere filmu, kedy tieto odporúčania môžu predstavovať filmové recenzie. Ďalšou motiváciou na vytvorenie týchto systémov bol narastajúci trend vzniku rôznych internetových služieb a e-shopov spoločne s enormným nárastom množstva informácii dostupných na internete a ich rôznorodosti. Pre používateľa to znamenalo zvýšenie množstva informácií, ktoré potrebuje spracovať predtým, ako je schopný nájsť a vybrať si objekt, ktorý potrebuje, čo viedlo k jeho váhavým a slabým rozhodnutiam [1][5]. Prínos väčšieho počtu možností malo namiesto pozitívneho účinku negatívny dopad na úžitok pre používateľa. Odporúčacie systémy sa však v posledných rokoch prejavili ako vhodný prostriedok na riešenie tohto problému [1].

Ako sa uvádza v [1], odporúčacie systémy sú teda primárne určené pre používateľov, ktorí nie sú dostatočne kompetentní alebo nemajú dostatočné množstvo skúseností na vyhodnotenie nadmerného počtu alternatívnych objektov, ktoré mu ponúkajú jednotlivé webové stránky. Pojem objekt je tu chápaný ako všeobecné pomenovanie pre výsledok odporúčacieho systému pri vytváraní odporúčaní pre používateľa, pričom sa systém väčšinou sústreďuje na špecifický druh objektu, ako napríklad články alebo knihy.

Odporúčací systém generuje odporúčané objekty na základe používateľovej požiadavky, pričom sa pri jej spracovaní berie do úvahy aj kontext používateľa a jeho potreby, s využitím rôznych typov znalostí a dát o používateľoch, dostupných objektoch a predošlých transakciách [1]. Tieto dáta sú obvykle uložené v databázach upravených podľa potrieb prevádzkovateľa e-shopov alebo internetových služieb, kde je daný odporúčací systém použitý.

Výber objektov na odporúčania pre používateľa môže byť podmienený napríklad najpredávanejšími objektmi v rámci e-shopu, historickými dátami o nákupoch používateľa, ktoré sú použité na predikciu jeho budúcich nákupov, alebo demografickými informáciami o používateľovi [1].

2.1.2.1 Personalizované odporúčania

Vzhľadom na to, že odporúčacie systémy napomáhajú e-shopom adaptovať sa na každého používateľa, sa dajú v širšom slova zmysle považovať za súčasť personalizácie v rámci e-shopu. Tieto systémy automatizujú personalizáciu na internete, a týmto umožňujú individuálnu personalizáciu pre každého používateľa. V snahe vytvoriť pre každého používateľa personalizované odporúčania sú rozličným používateľom ponúknuté odlišné návrhy objektov. Usporiadaný zoznam predstavuje najjednoduchšiu formu reprezentácie týchto odporúčaní [5].

2.1.3 Popis jednotlivých komponentov odporúčacích systémov

Informácie obsiahnuté v tejto časti práce sú čerpané prevažne zo zdroja [6].

Podľa [6] sa odporúčacie systémy skladajú z piatich hlavných komponentov (Obrázok 2.1):

1. zbieranie a spracovanie dát,
2. odporúčací model,
3. post spracovanie odporúčania,
4. online moduly,
5. používateľské rozhranie.

Tieto komponenty môžu byť vzhľadom na navrhnutú štruktúru vývoja vyvíjané paralelne alebo sekvenčne.

Návrh komponentu na spracovanie dát je špecifický pre každý prípad použitia. Medzi bežné procesy obsiahnuté v tomto komponente ale patrí očistenie a normalizácia dát, ako aj generovanie príznakov a definovanie selekčných možností. Vzhľadom na fakt, že odporúčací systém je závislý na vstupných dátach, kvalita tohto komponentu ovplyvňuje výsledné odporúčania získané z daného systému.

Odporúčací model má za úlohu vytvorenie odporúčaní pre používateľa, čo znamená, že je hlavným komponentom celého systému. Charakter vstupu záleží od typu použitého odporúčacieho modelu, pričom ho môžu tvoriť napríklad používateľove preferencie alebo popis ponúkaných objektov. Po spracovaní týchto vstupných informácii model predikuje objekty, ktoré by mohli byť predmetom záujmu daného používateľa.

V mnohých prípadoch je potrebné výsledok odporúčacieho procesu dodatočne spracovať pred tým, ako je ponúknutý a zobrazený používateľovi. Komponent na post spracovanie výslednej množiny odporúčaní zaručuje, že odporúčané objekty budú pre používateľa relevantné a nebudú vzdialené jeho preferenciám. Tento cieľ sa snaží dosiahnuť filtrovaním objektov vo výsledných odporúčaniach, opätovným hodnotením vybraných objektov, či prostriedkami napomáhajúcimi zvýšiť diverzitu odporúčaných objektov, vďaka čomu bude mať používateľ na výber z rôznorodejších objektov.

Obrázok 2.1 Komponenty odporúčacieho systému [6]

Okrem toho môže komponent na dodatočné spracovanie odporúčaní v sebe obsahovať určitú biznis logiku. Jednu z jej podôb môžu tvoriť určité obmedzenia, ktoré napríklad zabezpečia, aby sa isté druhy objektov neodporúčali vybraným typom používateľov. Účelom takýchto obmedzení nie je zvýšenie presnosti odporúčaní, ale plnenie stanovených biznis cieľov a hlavne zabezpečenie lepšej používateľskej skúsenosti.

Túto stratégiu môžeme z praxe ilustrovať na Amazone[2], ktorý používa pravidlá, na základe ktorých používateľovi neodporúča vypredané objekty, alebo také, ktoré si už kúpil. Netflix[3] svojím používateľom neodporúča filmy, ku ktorým nemajú práva na ich streamovanie vzhľadom na ich geografickú polohu. Takisto nenavrhuje detským používateľom filmy pre dospelých. Mendeley[4] používateľom neodporúča sledovanie výskumníkov, ktorých už sledujú alebo ktorí nemajú verejný profil, či nepovoľujú sledovanie svojich príspevkov iným výskumníkom [7].

Po vygenerovaní odporúčaní a ich dodatočnej úprave nasleduje zobrazenie navrhovaných objektov danému používateľovi. Tento krok má na starosti online modul, ktorý okrem iného môže zahŕňať aj A/B testovanie rôznych odporúčacích metód. Komponent totižto zaznamenáva informácie o interakciách používateľov s vygenerovanými odporúčaniami a o ich použití. Následne sa určuje, ktoré z týchto dát je potrebné uchovať na vyhodnotenie výkonu systému, ako aj na jeho učenie.

Posledným komponentom odporúčacieho systému je používateľské rozhranie. Na základe toho, ako bol tento komponent navrhnutý, sa rozhoduje, ako a kde sa vygenerované odporúčania zobrazia používateľovi, čo všetko sa z nich zobrazí a do akej miery vie používateľ so zobrazenými odporúčaniami interagovať.

---

[2] www.amazon.com
[3] www.netlix.com
[4] www.mendeley.com

2.2 Základné koncepty odporúčacích systémov

Ako už bolo spomenuté na začiatku tejto kapitoly, základnou úlohou odporúčacích systémov je nájsť objekty, ktoré by mohli byť pre používateľa užitočné. Odporúčací systém musí teda odhadnúť, ktoré objekty budú vhodné na odporúčanie. Aby to docielil, musí byť schopný predikovať utilitu objektov alebo aspoň vedieť porovnať niektoré objekty medzi sebou na základe ich utility a následne rozhodnúť, ktorý z nich bude vhodný na odporúčanie.

Niektoré systémy využívajú okrem odhadu utility aj určité heuristiky, čo je typický príklad pre znalostne orientované systémy[5]. Takéto systémy odhadujú utilitu objektov jednak využitím špecifického algoritmu a navyše používajú rozličné znalosti o používateľoch, objektoch a o samotnej funkcii utility [1].

Ako popisuje [1], niekedy je utilita určitého objektu vzhľadom na používateľa ovplyvnená aj takzvanými kontextovými premennými. Pod týmito premennými rozumieme faktory ako napríklad používateľova znalosť domény objektov, čas, v ktorom je toto odporúčanie vygenerované alebo používateľova momentálna poloha v prípade, ak je pre používateľa pri výbere objektu rozhodujúca vzdialenosť objektu od neho. Odporúčací systém by sa mal, prirodzene, vedieť adaptovať na tieto doplňujúce informácie, čo predstavuje väčšiu výzvu pri generovaní relevantných odporúčaní pre používateľa.

Podľa toho, nad akými doménami jednotlivé odporúčacie systémy operujú, aké znalostí pri generovaní odporúčaní využívajú a ktoré odporúčacie algoritmy aplikujú na odhad utility, rozlišuje [1] šesť tried odporúčacích systémov:

1. kolaboratívne odporúčacie systémy,
2. obsahovo orientované odporúčacie systémy[6],
3. demografické odporúčacie systémy,
4. znalostne orientované odporúčacie systémy,
5. komunitne orientované odporúčacie systémy[7],
6. hybridné odporúčacie systémy.

2.2.1 Kolaboratívne odporúčacie systémy

Odporúčacie systémy sú závislé na vstupných dátach, ktoré môžu mať rôzny charakter. Podľa [1] je najvhodnejšie vychádzať z kvalitných dát získaných z explicitnej spätnej väzby od používateľa, kedy priamo vyjadruje svoje preferencie na daný objekt. Nie vždy sú ale tieto dáta postačujúce na získanie kvalitných a relevantných odporúčaní pre používateľa. V tomto prípade si odporúčacie systémy odvodzujú používateľove preferencie z informácii o implicitnej spätnej väzbe. Tá zahŕňa informácie ako historické dáta o nákupoch, históriu prehľadávania, vyhľadávacie vzory či pohyby ukazovateľa myši na stránke. Tieto informácie nepriamo odrážajú používateľove preferencie na základe skúmania jeho správania.

---

[5] knowledge-based systems
[6] content-based recommendation systems
[7] community-based recommendation systems

Kolaboratívne odporúčacie systémy vychádzajú z predpokladu, že ak sa dvaja používatelia zaujímali alebo si zakúpili rovnaký objekt v minulosti, tak budú mať podobné preferencie aj v budúcnosti [8]. Vytvára reláciu pre dve odlišné entity – objekty a používateľov. Pri generovaní odporúčaní čerpá informácie z historických dát o interakciách používateľov, pričom sa pri danom používateľovi snaží nájsť určité patterny (vzorce) v jeho správaní sa [1].

Vo svojej podstate nevyžadujú a ani nevyužívajú informácie o samotných objektoch. Technika využívaná v tomto type odporúčacích systémov sa často nazýva aj kolaboratívne filtrovanie, keďže výber vhodného objektu na odporúčanie podlieha filtrovaniu z veľkého množstva objektov a používatelia navzájom implicitne kolaborujú [8]. Presnosť týchto systémov záleží na tom, ako kvalitne je definované susedstvo používateľov a na jednoznačnosti interakčných dát [9].

Na základe metódy, ktorú kolaboratívny odporúčací systém využíva, môžu byť tieto systémy rozdelené do dvoch kategórii [10]:

1. Neighbourhood metódy
   Na predikciu ohodnotenia pre nový objekt sa priamo využívajú ohodnotenia objektov jednotlivých používateľov.
2. Model-based metódy
   Ohodnotenia sa využívajú na učenie predikátového modelu, ktorý následne vytvára odhady pre nový objekt.

Nasledujúce definície týchto metód a popis ich fungovania sú čerpané zo zdroja [10].

2.2.1.1 Neighbourhood metódy

Neighbourhood metódy sa podľa toho, či sa zameriavajú na vzťahy medzi objektmi alebo používateľmi, rozlišujú na objektovo orientované metódy[8] alebo používateľsky orientované metódy[9].

Používateľsky orientované metódy hľadajú používateľov s podobnými preferenciami ako používateľ, pre ktorého sa systém snaží vygenerovať odporúčania. Navrhované objekty vyberá na základe objektov preferovaných týmito používateľmi. Systém využívajúci objektovo orientované metódy odporúča objekty podobné tým, ktoré daný používateľ už v minulosti preferoval. Podobnosť jednotlivých objektov sa určuje na základe spoločných výskytov v rámci všetkých dát – teda používateľ, ktorý si kúpil objekt *x*, si kúpil aj objekt *y*.

Síce je princíp oboch metód veľmi podobný, systémy využívajúce tieto metódy môžu pre rovnakého používateľa generovať rozdielne odporúčania.

2.2.1.1.1 Používateľsky orientované metódy

Používateľsky orientované metódy sa snažia pri generovaní odporúčaní pre vybraného používateľa nájsť takých používateľov, ktorí sú mu najviac podobní. Následne z objektov preferovaných týmito používateľmi vyberá objekty vhodné

[8] item-based methods
[9] user-based methods

na odporúčania, pričom môžu byť tieto objekty ováhované na základe podobnosti medzi daným používateľom a nájdenými jemu blízkymi používateľmi.

Proces na pozadí používateľsky orientovaných metód môže byť ilustrovaný s využitím matice preferencií, v ktorej riadky predstavujú jednotlivých používateľov a stĺpce objekty. Hodnota, ktorá je zaznamenaná na priesečníku používateľa s určitým objektom, predstavuje jeho ohodnotenie daného objektu na vybranej škále ohodnotenia.

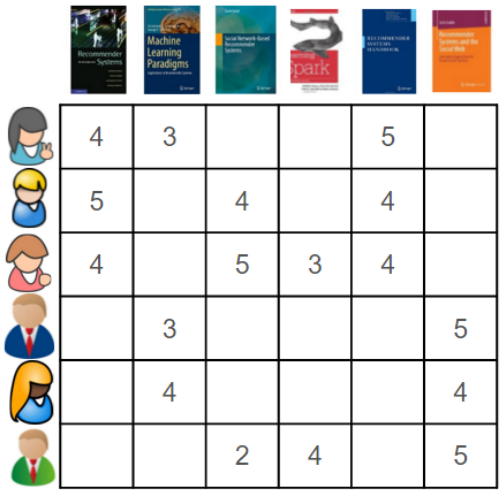

4	3			5	
5		4		4	
4		5	3	4	
	3				5
	4				4
		2	4		5

Obrázok 2.2 Príklad matice preferencií [10]

Obrázok 2.2 reprezentuje ohodnotenia kníh jednotlivými používateľmi, pričom všetky ohodnotenia sú na škále 1-5, kde 5 je najlepšie ohodnotenie. Ak sú tieto ohodnotenia binárneho charakteru, napríklad ako je zakúpenie objektu, táto hodnota je konštantná pre všetkých používateľov. V prípade, ak informácia o ohodnotení objektu daným používateľom nie je známa, táto hodnota je v matici preferencií prázdna (Obrázok 2.2).

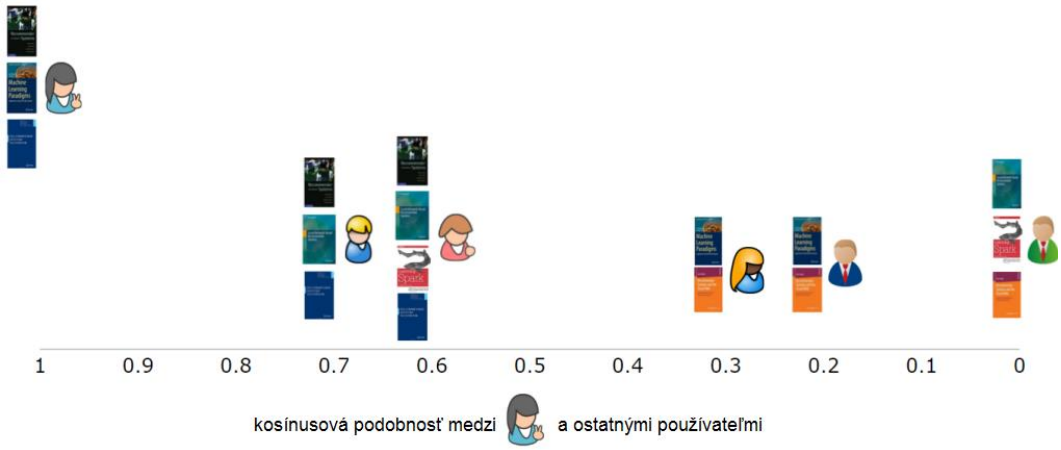

Obrázok 2.3 Príklad vyrátania podobností medzi prvým používateľom a ostatnými používateľmi s využitím kosínusovej podobnosti [10]

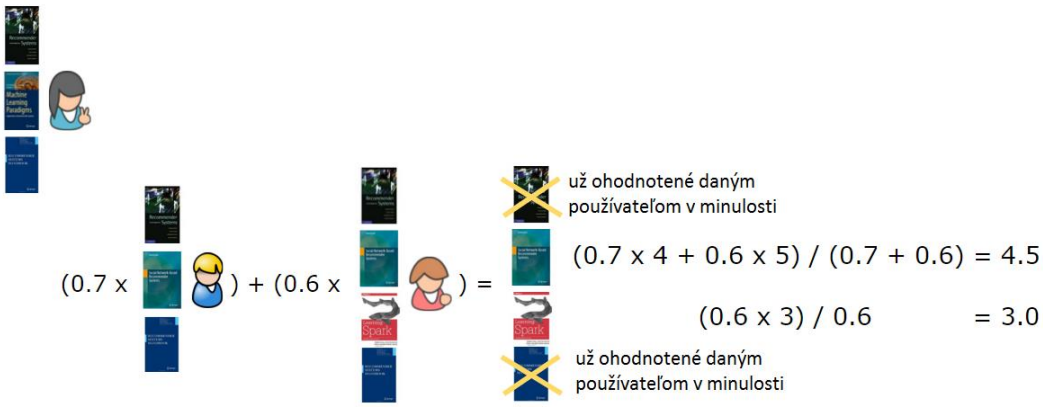

Obrázok 2.4 Ilustrovanie výsledného odhadu ohodnotenia objektov na základe ohodnotenia objektu podobným používateľom ováhovaným získanou hodnotou podobnosti medzi používateľmi [10]

Prvým krokom v tomto druhu metód je vyrátanie podobnosti medzi jednotlivými používateľmi na základe ich preferencií objektov (Obrázok 2.3). Reprezentácia používateľov má najčastejšie podobu vektorov alebo polí, ktoré obsahujú jednotlivé používateľove ohodnotenia objektov, a pomocou zvolenej metriky sa vyráta podobnosť medzi používateľmi.

Následne sa pre používateľa, pre ktorého majú byť vygenerované odporúčania, vyberie *n* používateľov, ktorí sú mu najpodobnejší na základe získaných hodnôt podobnosti. Na vytvorenie odporúčaní sa použijú objekty z množiny objektov preferovaných najpodobnejšími používateľmi, pričom sa vyfiltrujú tie, ktoré sa zhodujú s objektmi už preferovanými daným používateľom. Výsledné ohodnotenie objektu sa odhaduje na základe hodnoty ohodnotenia objektu podobným používateľom, ktorá môže byť ováhovaná získanou hodnotou podobnosti medzi daným a podobným používateľom (Obrázok 2.4).

2.2.1.1.2 Objektovo orientované metódy

Podobne ako u používateľsky orientovaných metód, aj u objektovo orientovaných metód je prvým krokom pri generovaní odporúčaní vyrátanie matice podobnosti.

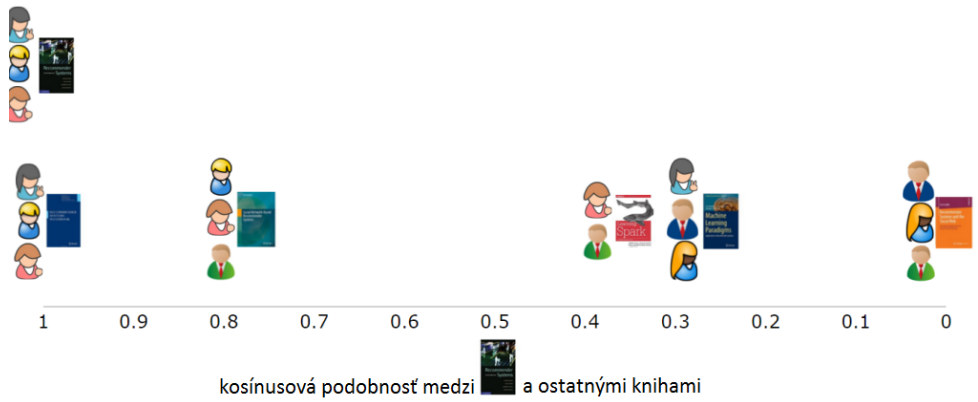

Obrázok 2.5 Príklad vyrátania podobností medzi prvým objektom a ostatnými s využitím kosínusovej podobnosti [10]

V tomto druhu metód sa ale podobnosti rátajú medzi jednotlivými objektmi (Obrázok 2.5). Tie sú reprezentované vektormi alebo poľami používateľov, ktorí ich v minulosti ohodnotili.

Po získaní podobností systém pristúpi ku generovaniu odporúčaní pre daného používateľa. Tie sa získavajú na základe objektov, ktoré v minulosti daný používateľ ohodnotil. Systém postupne prechádza všetky tieto objekty a pre každý vyberie také, ktoré sú mu najviac podobné. Odhad ohodnotenia najpodobnejších objektov je ovplyvnený hodnotou používateľovho ohodnotenia objektu, ktorému sú najviac podobné. Zo získanej množiny objektov systém vyfiltruje tie, ktoré používateľ už v minulosti ohodnotil. Výsledné objekty ešte môžu byť ováhované na základe podobnosti medzi pôvodnými objektmi z dát o danom používateľovi a im podobnými objektmi (Obrázok 2.6).

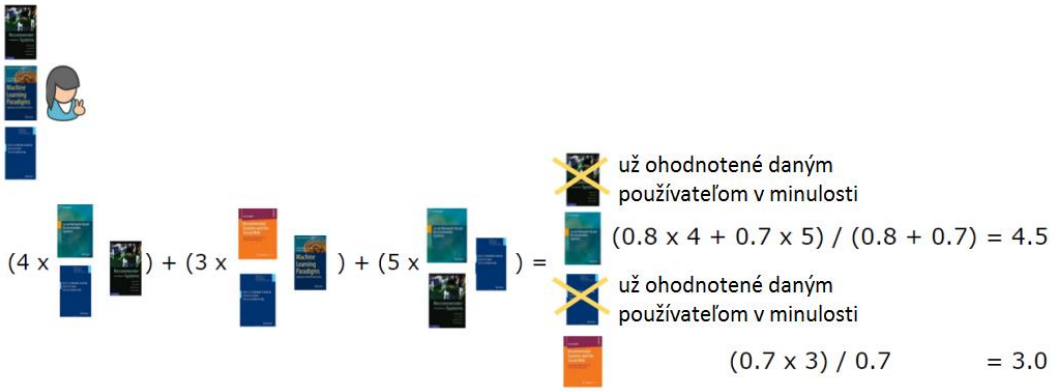

Obrázok 2.6 Ilustrovanie výsledného odhadu ohodnotenia objektov na základe ohodnotenia pôvodného objektu vybraným používateľom ováhovaným získanou hodnotou podobnosti medzi objektmi [10]

2.2.1.2 Model-based metódy

Vyššie popísané neighbourhood metódy používajú na odhad ohodnotenia objektu dáta o ohodnoteniach objektov používateľmi. Model-based metódy využívajú tieto informácie na naučenie prediktívneho modelu. Základnou myšlienkou tohto typu metód je modelovať interakcie medzi používateľmi a objektmi využitím algoritmov strojového učenia, ktoré sa snažia nájsť určité patterny v dátach. Medzi tieto algoritmy môžu patriť napríklad bayesovské siete, zhlukovanie, klasifikácia, regresia, maticová faktorizácia či obmedzené boltzmannove stroje[10].

2.2.1.3 Popularity bias

Ako už bolo spomenuté v tejto časti práce, kolaboratívne systémy sú závislé len na dátach o použití jednotlivých objektov používateľmi.

Táto skutočnosť ale spôsobuje jedno z obmedzení týchto systémov, a to fakt, že majú tendenciu odporúčať populárne objekty, čo môže predstavovať problém v prípade používateľov s unikátnymi preferenciami, teda používateľov, ktorí sa zaujímajú o objekty

[10] restricted boltzmann machines

s malým množstvom dát využitia. Tento problém je známy pod pojmom „popularity bias“ [10].

2.2.2 Obsahovo orientované odporúčacie systémy

Obsahovo orientované systémy spracovávajú výlučne historické informácie o interakciách vybraného používateľa a neberú do úvahy ostatných používateľov [9]. Zameriavajú sa na objekty, ktoré používateľ v minulosti ohodnotil, pričom analyzujú ich popis a informácie o nich a získavajú tak ich charakteristické znaky, na základe ktorých budujú používateľov profil. Tento profil predstavuje štruktúrovanú reprezentáciu používateľových preferencií prispôsobenú na odporúčanie nových objektov pre používateľa [1].

Objekty vhodné na odporúčanie vyberá na základe podobnosti atribútov s objektmi, ktoré používateľ v minulosti ohodnotil [1]. Od kolaboratívnych odporúčacích systémov (2.2.1) sa líšia v tom, že podobnosť objektov odvodzujú na základe ich obsahu, ktorý tvoria napríklad metadáta, popis objektu, klasifikovanie objektu, a nie na základe toho, ako s nimi používatelia interagujú [11].

Obsah objektov je reprezentovaný vo forme vektoru príznakov. Tieto systémy sú založené na dostupnosti popisu objektov, ktoré môžu byť manuálne zadané alebo automaticky extrahované, a na používateľovom profile, ktorý priraďuje dôležitosť týmto charakteristikám. Výhodou ich používania je, že pre dosiahnutie uspokojivých výsledkov nevyžadujú veľké množstvo používateľov, o ktorých má systém informácie, a nové objekty môžu byť súčasťou odporúčaní hneď, ako je dostupný jeho popis a jeho atribúty [8][11].

Proces na pozadí obsahovo orientovaných odporúčacích systémov môže byť opäť ilustrovaný s využitím matice preferencií, kde jednotlivé riadky predstavujú používateľov, stĺpce reprezentujú objekty a hodnoty na ich priesečníkoch predstavujú ohodnotenie konkrétneho objektu konkrétnym používateľom [11]. Príklad takejto matice zobrazuje Obrázok 2.2.

Prvým krokom na získanie odporúčaní je vyrátanie podobnosti medzi jednotlivými objektmi na základe ich obsahu. Ich obsah v tomto prípade predstavujú jednotlivé atribúty objektov, ako môže byť napríklad názov, popis objektu alebo kategória, do ktorej objekt v rámci kontextu daného e-shopu patrí.

Zaužívaným postupom je vyfiltrovanie takzvaných „stop words“ z obsahu, teda najbežnejších slov používaných v prirodzenom jazyku, ako sú napríklad krátke funkčné slová (slová ako predložky, spojky alebo zámená, ktoré sú používané na vyjadrenie vzťahu medzi slovami použitými vo vete[11]). Takto získaný obsah jednotlivých objektov je reprezentovaný ako vektor alebo pole slov, ktoré sú v obsahu obsiahnuté, čo ilustruje Obrázok 2.7, kde je obsah objektov tvorený ich názvami. Táto reprezentácia je následne použitá na vyrátanie podobností medzi jednotlivými objektmi, ktoré sú potom využité na generovanie odporúčaní pre daného používateľa.

[11] definícia z dictionary.cambridge.org

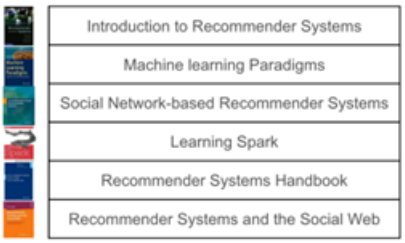

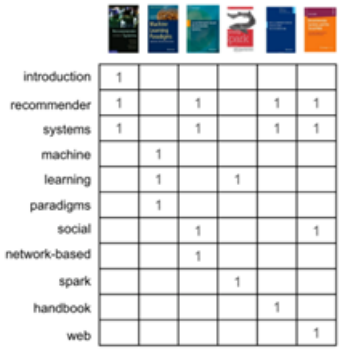

introduction	1					
recommender	1		1		1	1
systems	1		1		1	1
machine		1				
learning		1		1		
paradigms		1				
social			1			1
network-based			1			
spark				1		
handbook					1	
web						1

Obrázok 2.7 Príklad reprezentácie obsahu objektov

Systém prejde postupne všetky objekty, ktoré v minulosti používateľ ohodnotil, a ku každému objektu vyberie *n* takých objektov, ktoré sú mu najviac podobné. Zo získanej množiny objektov sa vylúčia tie, ktoré používateľ v minulosti už ohodnotil, a ováhujú sa na základe podobnosti medzi objektom z používateľových historických dát a jeho najpodobnejšími objektmi, pričom sa berie do úvahy aj hodnota ohodnotenia tohto objektu daným používateľom. Princíp je podobný ako pri objektovo orientovanom kolaboratívnom filtrovaní (2.2.1.1.2), ibaže v tomto prípade sa systém zameriava na obsah jednotlivých objektov, nie na používateľské dáta.

2.2.3 Demografické odporúčacie systémy

Demografické odporúčacie systémy sa usilujú o kategorizáciu používateľa vzhľadom na jeho individuálne atribúty a vytvárajú odporúčania na základe demografických tried [12]. Využívajú informácie z demografického profilu používateľa, v ktorom sa vyskytujú atribúty ako jeho vek, pohlavie, vzdelanie a podobne. U tohto typu systémov sa predpokladá, že pre rozličné demografické oblasti by mali byť generované rozdielne odporúčania [1].

Demografické odporúčacie systémy sú v [8] popísané ako systémy, ktoré vytvárajú kolaboratívny návrh založený na demografickom profile používateľa. Demografická informácia môže byť chápaná ako dodatočná zložka znalostí o používateľovi, ktorá môže byť využitá na vymedzenie podobných koncových používateľov na internete, čím sa tento typ systémov dá charakterizovať ako variant kolaboratívneho systému.

Ako je podotknuté v [13], demografické informácie ako príjem, národnosť, vek, pohlavie alebo povolanie sú zásadné pre množstvo aplikácii. Napríklad informácia o veku môže byť užitočná pri odporúčaní filmov, pričom informácia o príjme je dôležitá na výber vhodného odporúčania na turistické miesto. Podľa [1] množstvo webových stránok využíva jednoduché a efektívne personalizované riešenia založené na demografických údajoch a tieto systémy sú populárne hlavne v marketingovej sfére. Používatelia sú

napríklad priradzovaní rozličným webovým stránkam podľa ich jazyka alebo krajiny, v ktorej sa nachádzajú. Tak isto sú väčšinou mužské a ženské požiadavky v marketingu rozdielne, a preto je vhodné brať tento atribút do úvahy pri odporúčacom procese [13].

Tento druh odporúčacích systémov je využívaný aj pri hybridizácii niektorých iných druhov odporúčacích systémov, ako to bolo použité v prácach [14], [15], [16].

2.2.4 Znalostne orientované odporúčacie systémy

Znalostne orientované odporúčacie systémy predpokladajú detailnejšie dáta o atribútoch objektov ako druhy systémov spomenuté v predchádzajúcich podkapitolách. Generujú odporúčania nezávisle na dátach o interakciách medzi používateľmi a objektmi. Objekty vhodné na odporúčania sú vyberané na základe podobnosti medzi používateľovými požiadavkami a danými objektmi alebo na základe explicitných odporúčacích pravidiel, pričom celý odporúčací proces je interaktívny [8]. Odporúčanie určitého objektu používateľovi je založené na báze znalostí o tom, ako určitý objekt uspokojí používateľove potreby a preferencie a ako veľmi nápomocný je tento objekt v konečnom dôsledku pre používateľa [1].

V rámci kontextu e-shopov sú častým prípadom takzvaní „jednorazoví nákupcovia“. Pri takýchto používateľoch sa systém nemôže spoliehať na existenciu historických dát o ohodnoteniach, čo, ako už bolo spomenuté, je predpokladom pre kolaboratívne filtrovanie (2.2.1) a obsahovo orientované systémy (2.2.2). V týchto prípadoch sú potrebné detailnejšie a štruktúrovanejšie obsahy objektov. Ďalej je potrebný systém, ktorý využíva dodatočnú a koncovo významovú znalosť na generovanie odporúčania [8].

Takisto v e-shopoch ponúkajúcich určité druhy objektov nie sú spomenuté typy odporúčacích systémov postačujúce. Pri objektoch, ktoré nie sú nakupované často, ako napríklad autá alebo domy, nie je väčšinou možné získať dostatočné množstvo dát o ohodnotení týchto objektov používateľmi. V prípade nákupu elektroniky zase rozhoduje aj to, ako sú tieto dáta staré. Nároky používateľov pri tomto type objektov sa rýchlo vyvíjajú, preto ohodnotenia spred niekoľkých rokov už pri generovaní odporúčaní nie sú viac nápomocné [8].

Znalostne orientované systémy často využívajú dodatočné informácie o danom používateľovi a dostupných objektoch, ktoré sú vo väčšine prípadov poskytované manuálne. V prípade komplexnejších objektov, ako napríklad autá alebo domy, chce používateľ obvykle sám definovať svoje požiadavky na objekt. Medzi takéto požiadavky môže patriť napríklad ohraničenie ceny za objekt, či konkrétne parametre [8].

Autori [1] rozlišujú dva typy znalostne orientovaných systémov:

1. case-based,
2. constraint-based.

Oba typy zhromažďujú požiadavky používateľa, automaticky navrhujú úpravu nekonzistentných požiadaviek, pri ktorých systém nie je schopný nájsť vhodné odporúčania, a výsledky odporúčania sú objasnené. Hlavný rozdiel je v spôsobe, akým sú odporúčania získané.

V case-based systémoch funkcia podobnosti odhadne, ako veľmi sa odporúčané objekty zhodujú s používateľovými požiadavkami. Tieto objekty sú určované na základe rôznych metrík podobnosti. Constraint-based systémy využívajú preddefinovanú bázu

znalostí, ktorá obsahuje explicitné pravidlá o spájaní používateľových požiadaviek s príznakmi jednotlivých objektov.

Interakciu medzi používateľom a znalostne orientovaným odporúčacím systémom popisuje [8] v nasledujúcich krokoch:

1. Používateľ špecifikuje svoje prvotné požiadavky. To môže byť dosiahnuté napríklad formulárom na webovej stránke e-shopu, pričom sa môže využívať uniformný formulár pre každého používateľa alebo personalizovaný formulár na základe situácie, v ktorej je použitý. Ďalším zaužívaným spôsobom je získanie používateľových preferencií prostredníctvom otázok na používateľa, ktoré mu môžu byť položené všetky naraz alebo postupne.
2. Po získaní dostatočných informácií o používateľových preferenciách nasleduje ich spracovanie systémom a generovanie odpovedajúcich odporúčaní, ktoré sú poskytnuté používateľovi. Používateľ si môže zažiadať o dodatočné vysvetlenie, prečo mu bol daný objekt navrhnutý.
3. Používateľ si môže upraviť svoje požiadavky na objekt, či už z dôvodu, aby videl ďalšie alternatívy objektov alebo zúžil množinu objektov odpovedajúcich jeho požiadavkám.

2.2.5 Komunitne orientované odporúčacie systémy

Báza pre komunitne orientované odporúčacie systémy je tvorená dátami o preferenciách priateľov vybraného používateľa. Základnou myšlienkou tohto typu systémov je krédo: „Povedz mi, kto sú tvoji priatelia a ja ti poviem, kto si“.

Praxou sa totižto ukázalo, že používatelia majú väčšiu tendenciu spoliehať sa na odporúčania od svojich priateľov, ako na odporúčania od podobných, no anonymných používateľov. Táto myšlienka spolu s nárastom popularity otvorených sociálnych sietí podnietila narastajúcu pozornosť na komunitne orientované systémy, ktoré sa zvyknú označovať aj ako sociálne odporúčacie systémy [1].

2.2.6 Hybridné odporúčacie systémy

Podstatou hybridných algoritmov je spojenie dvoch alebo viacerých algoritmov, pričom sa využívajú výhody prvého algoritmu na pokrytie slabých miest toho druhého [17].

Každý z vyššie uvedených systémov operuje nad dátami z rozdielnych zdrojov a aplikuje rozdielne paradigmy pri generovaní odporúčaní. Kolaboratívne filtrovanie (2.2.1) využíva dáta z profilu používateľa s dátami o spoločenstve, obsahovo orientované systémy (2.2.2) sa spoliehajú na atribúty objektov a ich textové opisy, znalostne orientované metódy (2.2.4) generujú dáta na základe explicitných znalostí [8].

Vstupy pre odporúčací systém rozdeľuje [8] do štyroch kategórii (Obrázok 2.8):

1. Profil používateľa a parametre kontextu.
   Táto kategória obsahuje informácie o používateľovi a o situácii, v ktorej sa používateľ nachádza. Profil používateľa predstavujú informácie o konkrétnom používateľovi, do čoho spadá napríklad jeho doterajšie ohodnotenie objektov, jeho odpovede získané pri interakcii

s odporúčacím systémom, informácie o demografickom zázemí. Parametre kontextu obsahujú napríklad informácie o ročnom období, o aktuálnej lokácii používateľa alebo o tom, akí ľudia mu robia spoločnosť pri interakcii s ponúkanými objektmi.

2. Dáta o komunite.
3. Atribúty objektov.
4. Znalostné modely.

Žiadna zo spomenutých metód nie je schopná operovať nad všetkými kategóriami vstupov a produkovať relevantné výsledky (Tabuľka 2.1). Každá metóda má svoje výhody, ale aj svoje limity.

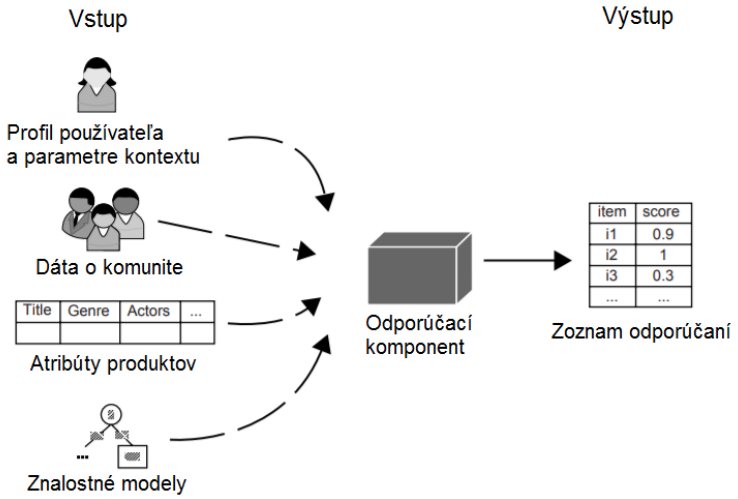

Obrázok 2.8 Odporúčací systém ako black box [8]

Tabuľka 2.1 Rozdelenie odporúčacích systémov podľa kategórie vstupov, ktoré spracúvajú [8]

Kategória vstupu / Typ modelu	Profil používateľa a parametre kontextu	Dáta o komunite	Atribúty objektov	Znalostné modely
Kolaboratívne filtrovanie	✓	✓	✗	✗
Obsahovo orientované systémy	✓	✗	✓	✗
Znalostne orientované systémy	✓	✗	✓	✓

Kolaboratívne filtrovanie má limity pri uvedení nového objektu, keďže tento objekt zatiaľ nemá žiadne využitie ani ohodnotenie. Nové objekty ale nepredstavujú problém pre obsahovo orientované systémy, keďže ich obsahy a príznaky sú väčšinou dostupné už pri ich uvedení [8]. Kombináciou týchto dvoch odporúčacích techník je možné vytvoriť odporúčací systém, ktorý vie prekonať hranice jednotlivých prístupov, ako napríklad

cold-start problém (2.3) alebo popularity bias (2.2.1.3), čím môžu byť dosiahnuté precíznejšie odporúčania a lepšie výsledky [17].

Existuje niekoľko spôsobov ako kombinovať dve alebo viac odporúčacích techník [17]:

1. Vážená metóda
   Finálne odporúčanie vzniká kombináciou výstupov z jednotlivých techník, ktoré majú priradené rozličný stupeň dôležitosti na základe skóre, ktoré predstavuje formu jednotlivých výstupov.
2. Prepínanie
   Systém prepína medzi jednotlivými technikami podľa situácie, v ktorej má vytvoriť odporúčania.
3. Mixovanie
   Odporúčania z niekoľkých techník sú prezentované používateľovi v rovnakom čase.
4. Kombinácia príznakov
   Kombinácia príznakov z rôznych odporúčacích zdrojov vytvára vstup pre jednu techniku.
5. Kaskádová metóda
   Výstup z jednej techniky je použitý ako vstup do druhej so snahou o vylepšenie konečného výsledku.
6. Augmentácia príznakov
   Výstup z jednej techniky je použitý ako vstupný príznak pre druhú techniku.
7. Meta-level
   Model naučený jedným odporúčacím systémom je použitý ako vstup do druhého.

Týchto sedem spôsobov môže byť podľa [8] abstrahovaných do troch základných návrhov:

1. Monolitický
   Spája aspekty niekoľkých odporúčacích stratégii do jedného systému (Obrázok 2.9). Takéto hybridné odporúčacie systémy používajú napríklad dodatočné vstupné dáta charakteristické pre iný typ odporúčacej metódy alebo sú vstupné dáta rozšírené jednou metódou a spracované druhou. Patrí sem napríklad obsahovo orientovaný systém, ktorý okrem atribútov objektov skúma aj dáta o komunite.

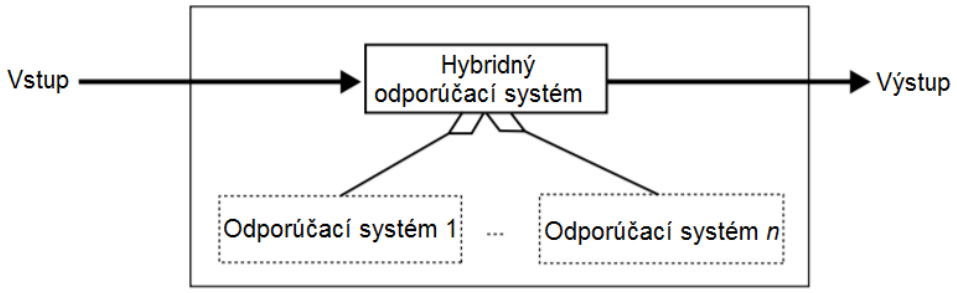

Obrázok 2.9 Schéma monolitického hybridného odporúčacieho systému [8]

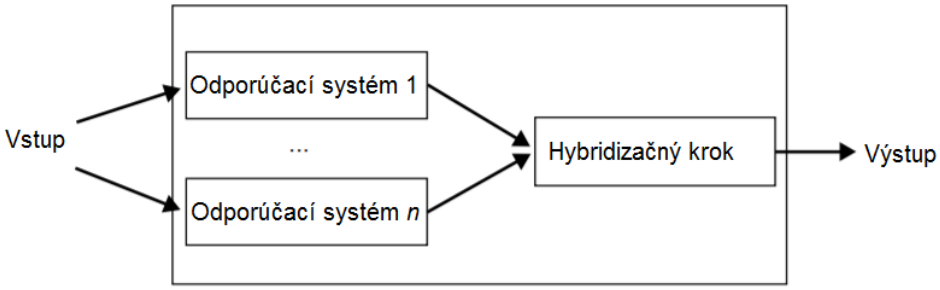

Obrázok 2.10 Schéma paralelného hybridného odporúčacieho systému [8]

2. Paralelný
   Jednotlivé metódy pracujú nezávisle a produkujú samostatný zoznam odporúčaných objektov, pričom sú tieto výsledky následne kombinované do konečnej množiny využitím rozličných stratégii (Obrázok 2.10). Rozlišuje sa vážená, zmiešaná a prepínacia stratégia.
   a. Vážená stratégia
      Objekty sú do výslednej množiny odporúčaných objektov vybrané na základe sumy ováhovaných skóre, ktoré získali v jednotlivých odporúčacích metódach, ktorými boli vygenerované.
   b. Zmiešaná stratégia
      Z výsledkov všetkých metód sa vyberie *k* najlepších objektov podľa ich skóre, ktoré v konkrétnej metóde získali.
   c. Prepínacia stratégia
      Nad všetkými použitými odporúčacími metódami existuje systém, ktorý na základe profilu používateľa a kvality výsledkov odporúčacieho procesu rozhoduje, ktorá z metód bude použitá.
3. Pipeline
   Výstup z jednej odporúčacej metódy sa stáva vstupom pre nasledujúcu, pričom optimálne táto nasledujúca metóda môže využiť na vstupe aj niektoré originálne vstupné dáta (Obrázok 2.11).

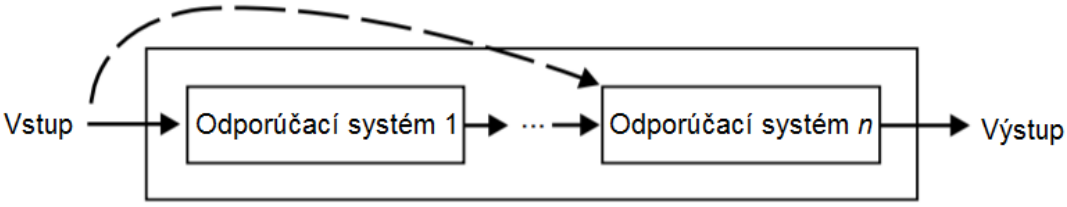

Obrázok 2.11 Schéma pipeline hybridného odporúčacieho systému [8]

2.3 Cold start problém

Cold start problém odkazuje na situáciu, kedy odporúčací systém nie je schopný vygenerovať relevantné odporúčania v dôsledku nedostatočných počiatočných informácií o správaní požívateľa v rámci daného e-shopu – teda nákup objektov, ohodnotenia objektov, a podobne [2].

Podľa rozdelenia v [2] sa rozlišujú tri druhy cold start problému:

1. nová komunita,
2. nový objekt,
3. nový používateľ.

2.3.1 Problém nového objektu

Problém nového objektu spočíva v situácii, kedy by mal odporúčací systém odporučiť novo pridaný objekt, s ktorým zatiaľ neexistujú žiadne interakcie od používateľov alebo len veľmi málo [10]. Z tohto dôvodu je veľmi malá pravdepodobnosť, že sa vyskytne medzi odporúčanými objektmi, a tak sa môže stať, že ho väčšina používateľov ani nepostrehne, a teda nebude v ich záujme ho ohodnotiť [2].

2.3.2 Problém nového používateľa

Problém nového používateľa predstavuje jednu z najväčších výziev pri návrhu odporúčacieho systému a pri jeho zavedení do praxe. Tento problém spočíva v tom, že odporúčací systém nie je schopný vytvoriť vhodné odporúčania pre používateľa, ktorý nemal žiadnu používateľskú aktivitu alebo len veľmi malú [10].

Používateľ po prvých ohodnoteniach väčšinou očakáva, že odporúčací systém bude schopný vytvoriť pre neho personalizované odporúčania, čo v prípade niektorých metód nie je možné (napr. kolaboratívne filtrovanie). Takto nedostane kvalitu služby, akú predpokladal, čo ho môže odradiť od používania systému [2].

Problém nového používateľa sa môže dotýkať aj používateľov vracajúcich sa do e-shopu. Odporúčací systém totižto pri každej ďalšej používateľovej návšteve nemôže vedieť, či sa používateľ stále zaujíma o podobné objekty ako v prípade jeho predošlej návštevy alebo sa jeho záujem presunul na iný typ objektov. Preto je vhodné, aby odporúčací systém bol schopný rozlíšiť aktuálny používateľov záujem po prvých pohyboch na stránke [18].

2.3.3 Prehľad niektorých riešení cold start problému

Ako je poznamenané v [19], väčšina návrhov odporúčacích systémom má tendenciu riešiť tento problém získaním informácii od používateľa cez ohodnotenie vybraných objektov na začiatku alebo položením niektorých demografických otázok a následným použitím stereotypov (napr. starší ľudia majú radi klasickú hudbu). Nie je ale jednoduché rozhodnúť, aké objekty budú vhodné na pochopenie používateľových preferencií hneď na začiatku, zatiaľ čo stereotypy môžu byť v niektorých prípadoch ofenzívne a nesprávne.

Ďalšie riešenie spočíva napríklad vo využití hybridných prístupov. Prehľad týchto prístupov obsiahnutých v [2] spomína spojenie metód ako kolaboratívne filtrovanie s obsahovo orientovanými metódami, demograficky orientované metódy a kolaboratívnym filtrovaním či sociálne orientované kolaboratívne filtrovanie.

Leung a kol. vo svojej práci [20] navrhli prístup využívajúci cross-level asociačné pravidlá (CLARE) prinášajúce obsahové informácie o objektoch z domény do kolaboratívneho filtrovania. Kim a kol. [21] využili kolaboratívne tagovanie na pochopenie a filtrovanie používateľových preferencií. Martinez a kol. [22] navrhli spojenie kolaboratívneho filtrovania a znalostne orientovaného algoritmu. Weng a kol. [23] vytvorili techniku kombinujúcu používateľove preferencie a doplňujúce taxonomické preferencie.

Bobadilla a kol. vo svojom článku [24] prezentovali nový spôsob merania podobnosti medzi používateľmi v kolaboratívnom filtrovaní vylepšenú o optimalizáciu založenú na neurónovom učení. Mariappan a Sobhanam [25] skombinovali asociačné pravidlá a zhlukovanie. Cohen a Sahebi [26] využili informácie o komunitách extrahovaných z rôznych dimenzií sociálnych sietí. Zhang a kol. [27] zvolili prístup využívajúci sociálne tagy.

3 Príklady použitia odporúčacích systémov

3.1 Pozitívny vplyv odporúčacích systémov na oblasť e-komerčného predaja

Ako je popísané v [5], odporúčacie systémy zvyšujú e-komerčný predaj niekoľkými spôsobmi:

1. „Browsers into buyers“
   V množstve prípadov sa stáva, že používatelia si prechádzajú jednotlivé stránky e-shopu bez toho, aby si niečo kúpili. Odporúčacie systémy im môžu pomôcť nájsť objekty, ktoré by ich mohli zaujímať, a ktoré by si nakoniec mohli kúpiť.
2. Krížový predaj[12]
   Podľa definície uverejnenej na [28] je krížový predaj obchodná taktika, ktorej cieľom je predať viac tovaru alebo služieb odporúčaním súvisiaceho tovaru.
   Odporúčacie systémy napomáhajú rozvíjať krížový predaj navrhovaním dodatočných objektov používateľovi, ktoré by si eventuálne tiež chcel kúpiť. Ak sú tieto systémy dobre navrhnuté a produkujú dobré výsledky, priemerná veľkosť objednávky sa môže zvýšiť.
   Táto taktika môže byť využitá napríklad počas procesu dokončovania objednávky, kde odporúčací systém navrhne používateľovi objekty na základe objektov nachádzajúcich sa v jeho nákupnom košíku.
3. Vernosť
   Vzhľadom na veľký rozmach e-shopov dostupných na internete a narastajúcu konkurenciu, e-shopy v súčasnej dobe bojujú o vernosť používateľov. Odporúčacie systémy pomáhajú vytvárať vzťah medzi používateľom a internetovým obchodom, ktorý má pridanú hodnotu, a zvyšujú ich vernosť.
   E-shopy, ale aj iní internetoví prevádzkovatelia, investujú do učenia sa o ich používateľoch a do pochopenia ich potrieb, k čomu využívajú práve odporúčacie systémy. Snažia sa tak o vytvorenie rozhrania pre používateľa, ktoré odráža jeho záujmy a potreby. Čím viac používateľ interaguje s odporúčacím systémom a využíva ho, čím ho učí, čo potrebuje, tým viac je verný danej stránke.

[12] cross-sell

3.2 Konkrétne príklady použitia odporúčacích systémov vybranými e-shopmi

3.2.1 Amazon.com

Ako popisuje [5], Amazon.com využíva v sekcii kníh hneď niekoľko typov odporúčacích systémov:

1. „Customers who Bought“
   Amazon.com obsahuje informačnú stránku o každej ponúkanej knihe. Používateľ na nej nájde detaily o danej knihe, informácie týkajúce sa nákupu danej knihy, a tak isto sekciu s odporúčaniami „Customers who Bought“. Tie sú tvorené dvoma samostatnými zoznamami s odporúčanými objektmi.
   Prvý zoznam obsahuje knihy, ktoré sú často nakupované používateľmi, ktorí si tak isto kúpili knihu, na ktorej informačnej stránke sa daný používateľ momentálne nachádza.
   Druhý zoznam odporúča autorov, ktorých knihy sú často kupované zákazníkmi, ktorí si zakúpili diela autora knihy, na ktorej informačnej stránke sa daný používateľ momentálne nachádza.
   Obrázok 3.1 zobrazuje odporúčania vygenerované po zobrazení informačnej stránky knihy *Big Data: A Revolution That Will Transform How We Live, Work and Think* od autorov Viktor Mayer-Schonberger a Kenneth Cukier.
2. „Eyes“
   Funkcia „Eyes“ predstavuje pre používateľa možnosť nechať si zasielať upozornenia na nové produkty, ktoré boli pridané do Amazon.com katalógu. Zákazník zadá požiadavku obsahujúcu meno autora, titul knihy, predmet, ISBN alebo informácie o dátume publikácie. Na vytvorenie dotazu na upozornenia môže zákazník použiť jednoduché, ale aj zložitejšie kritériá založené na boolean logike (AND/OR). Požiadavky môžu byť zadané aj priamo z ktorejkoľvek stránky na vyhľadávanie výsledkov, čím sa vytvorí trvalá požiadavka založená na vyhľadávaní.

Obrázok 3.1 Príklad odporúčaní vygenerovaných systémom “Customers who Bought” [29]

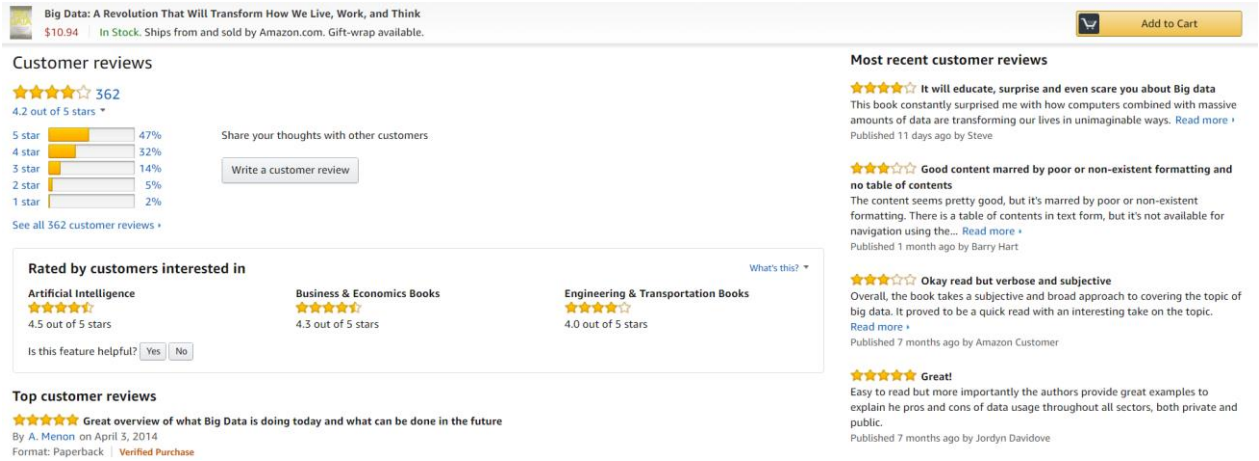

Obrázok 3.2 Príklad „Customer reviews“ na Amazon.com

3. „Amazon.com Delivers“
   Táto služba je obdobou funkcie „Eyes“. Používateľ si zo zoznamu kategórii alebo žánrov vyberie tie, ktoré preferuje. Editori stránok následne pravidelne posielajú odoberateľom notifikácie vo forme emailov, v ktorom upriamia ich pozornosť na posledné odporúčania vo vybranej kategórii.
4. „Book matcher“
   Funkcia „Book matcher“ umožňuje používateľovi poskytnúť priamu spätnú väzbu o knihe, ktorú prečítal. Jednotlivé knihy ohodnocuje na škále 1-5, pričom 1 znamená „nenávidím to“ a 5 znamená „zbožňujem to“. Po ohodnotení niekoľkých kníh si používateľ môže vyžiadať odporúčania kníh, ktoré by sa mu mohli páčiť. Následne sa zákazníkovi objaví niekoľko kníh, ktoré korelujú s používateľovými preferenciami a neboli ním ešte ohodnotené. Neskôr môže používateľ pridať spätnú väzbu na odporučené knihy.
5. „Customer reviews“
   Funkcia „Customer reviews“ ponúka používateľom textové odporúčania, ktoré sú založené na názore iných zákazníkov. Na každej informačnej stránke knihy sa nachádza zoznam ohodnotení v podobe 1 až 5 hviezdičiek a komentáre napísané zákazníkmi, ktorí si danú knihu prečítali (Obrázok 3.2). Tieto komentáre sú rozdelené do dvoch skupín, a to komentáre s najlepším ohodnotením (*Top customer reviews*) a naposledy pridané komentáre (*Most recent customer reviews*). Zákazník má teda možnosť zohľadniť tieto názory pri svojom rozhodovaní o kúpe knihy.

3.2.2 eBay

Odporúčací systém v eBay[13] popisuje zdroj [5]. Tento e-shop poskytuje svojím používateľom službu „Feedback Profile“, ktorá umožňuje ako nákupcom, tak aj predávajúcim prispievať do profilov spätnej väzby[14] iných používateľov, s ktorými uskutočnili nejakú obchodnú činnosť. Táto spätná väzba pozostáva z ohodnotenia spokojnosti na škále „spokojný“ – „neutrál“ – „nespokojný“ a z komentára k inému používateľovi.

Spätné väzby sú následne využívané odporúčacím systémom pre nakupujúcich, ktorí majú možnosť vidieť profil predávajúceho. Tento profil je tvorený tabuľkou (Obrázok 3.3), v ktorej sa nachádza počet každého typu ohodnotenia, ktoré bolo pridané za posledný mesiac, posledných 6 a 12 mesiacov (*Recent Feedback ratings*), ako aj celkové zhrnutie (*Detailed seller ratings*). Zákazník si môže takto počas svojej požiadavky prechádzať jednotlivé hodnotenia a komentáre o predajcoch.

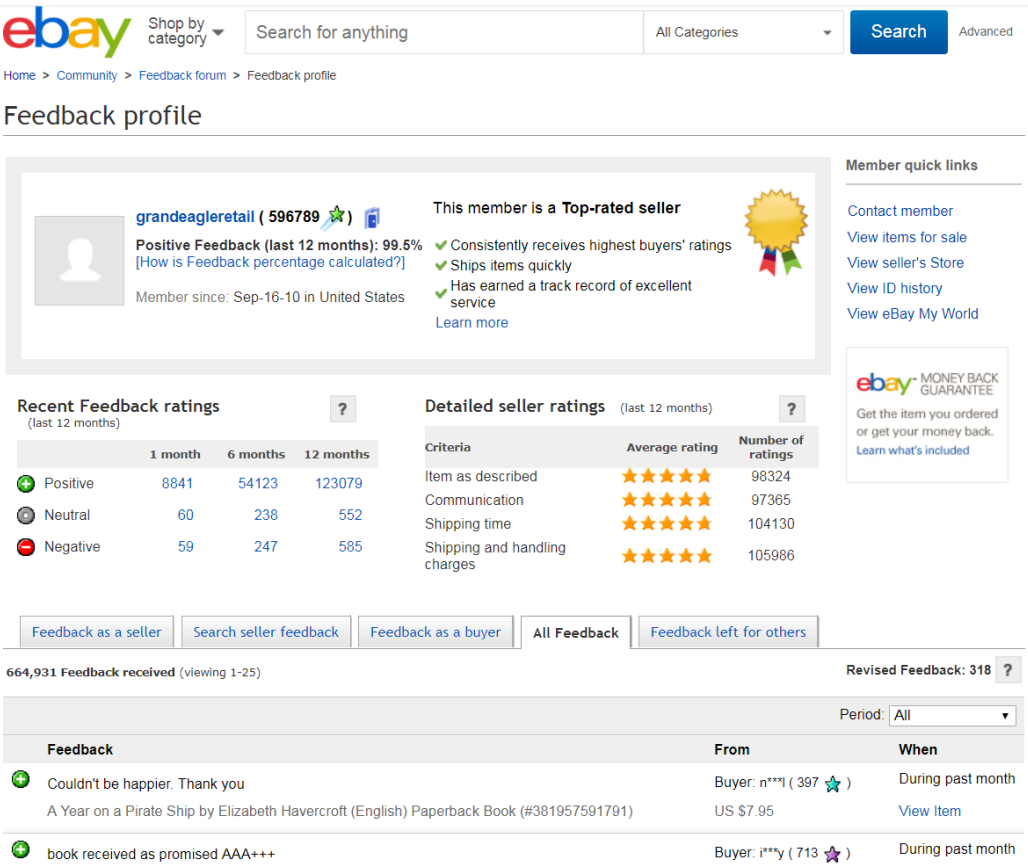

Obrázok 3.3 „*Feedback Profile*” predajcu *grandeagleretail* na ebay.com

[13] www.ebay.com
[14] feedback profile

3.2.3 Netflix

Netflix je správca a prevádzkovateľ rozmernej kolekcie filmov a televíznych programov, ktorú ponúka svojim odoberateľom prostredníctvom streamovania priamo do ich počítača alebo televízora. Profituje z predplatného svojich používateľov, pričom môžu svoje predplatné kedykoľvek zrušiť, preto je pre Netflix kľúčové, aby bol pre svojich odoberateľov stále zaujímavý a atraktívny.

Pre dosiahnutie tohto cieľa využíva aj odporúčací systém. Návrh tohto systému v Netflix-e úspešne kombinuje všetky komponenty odporúčacieho systému, čím bol vytvorený komerčne úspešný produkt. Nasledujúce odseky popisujú jednotlivé odporúčania generované týmto systémom z pohľadu používateľa Netflix-u a autora článku [30].

Keď sa prihlási už zaregistrovaný používateľ, Netflix si hneď po prihlásení pýta identifikáciu používateľa. Netflix totižto umožňuje, aby pod jednou domácnosťou mohlo byť vytvorených niekoľko profilov. Pre odporúčací systém je táto identifikácia veľmi nápomocná, keďže rôzni používatelia môžu mať odlišné preferencie.

Po identifikácii používateľa nasleduje presmerovanie na hlavnú stránku. Práve táto stránka je miestom zobrazenia väčšiny odporúčaných výsledkov. Podoba týchto odporúčaní sa dá popísať ako posuvné pásy[15], ktoré sú naplnené jednotlivými ponukami filmov a televíznych programov (Obrázok 3.4).

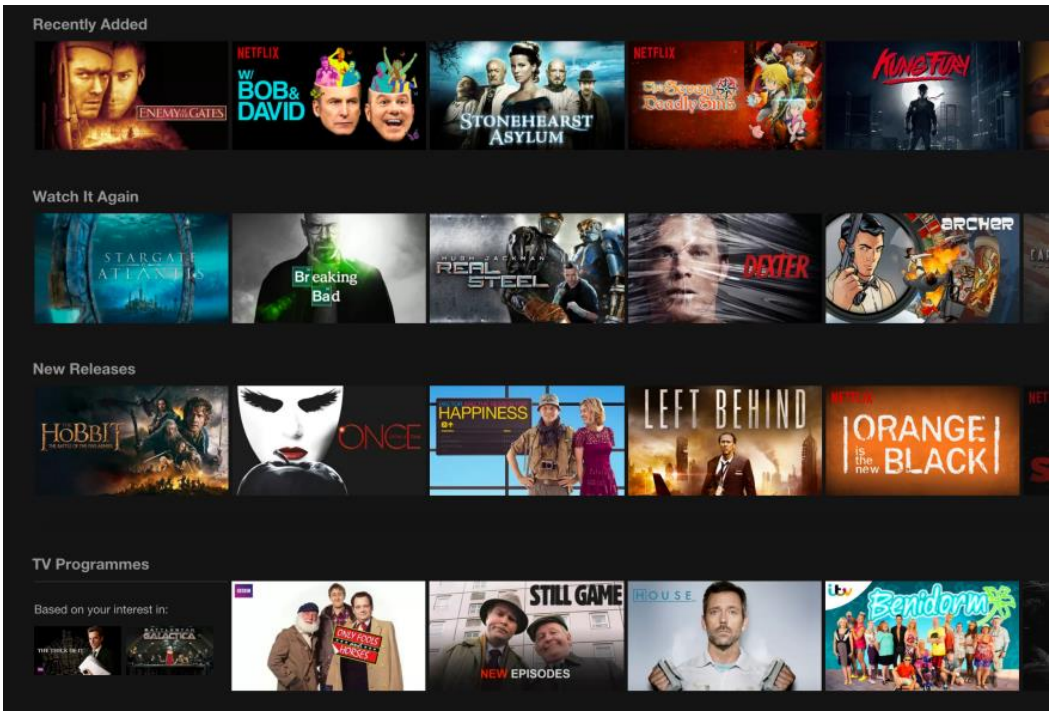

Obrázok 3.4 Ukážka odporúčaní prezentovaných používateľovi Netflix-u [30]

[15] carousels

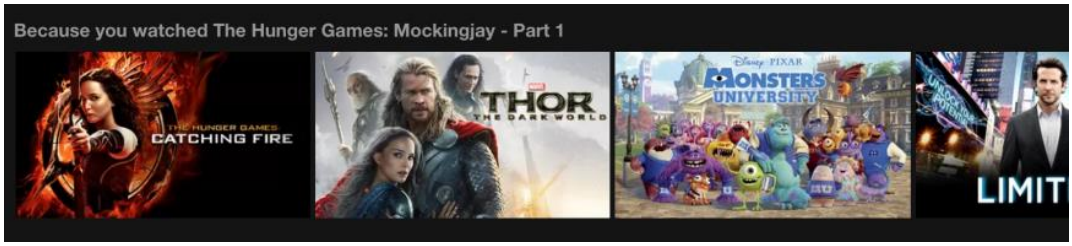

Obrázok 3.5 Odporúčania filmov na Netflix založené na filme pozretým daným používateľom

Prvý z týchto pásov obsahuje filmy, ktoré boli prednedávnom pozreté daným používateľom. Napriek tomu, že tieto filmy neboli vygenerované odporúčacím systémom, hrajú dôležitú úlohu vo vytváraní vzťahu s používateľom, čím sa upevňuje jeho dôvera.

Druhý pás v poradí obsahuje filmy, ktoré používateľ označil ako tie, ktoré by si rád v budúcnosti pozrel, ale momentálne na ne nemá čas. Napriek tomu, že tento zoznam opäť nie je výsledkom odporúčacieho systému, dá sa považovať ako zoznam filmov, ktoré si používateľ odporúča sám sebe.

Tretí zoznam obsahuje filmy, ktoré sú populárne v rámci komunity odoberateľov Netlix-u. Tento zoznam je personalizovaný pre každého používateľa, takže nie všetci používatelia vidia rovnaký výber filmov.

Nasleduje pás, ktorý odporúča tie filmy, ktoré sú momentálne populárne, respektíve sú v súčasnosti trendom. Tieto odporúčania sú tak isto personalizované. Rozdiel medzi týmito dvoma zoznamami podľa autora článku nie je úplne jednoznačný, dá sa ale predpokladať, že populárne filmy majú tento prívlastok na základe dlhšieho časového obdobia.

Ďalší zoznam obsahuje filmy, ktoré boli nedávno pridané a systém ich vyhodnotí ako filmy, ktoré by mohli danému používateľovi vyhovovať. Takýto odporúčací prístup je vhodný pre kolekciu objektov, ktoré sa obmieňajú dostatočne často na to, aby sa systém vedel zamerať na také produkty, ktoré boli nedávno pridané.

Nasleduje zoznam podobný ako prvý opísaný zoznam, ktorý obsahoval nedávno pozreté filmy. Tak isto obsahuje filmy, ktoré si používateľ už pozrel, ale tieto filmy nie sú zoradené podľa časovej postupnosti, v ktorej boli pozreté, ako to bolo u prvého spomenutého zoznamu. Tieto odporúčania nemusia byť nutne výsledkom odporúčacieho systému, môžu byť zobrazované čisto len na základe histórie používateľa. Autor článku sa ale domnieva, že ich poradie je dané určitou zoraďovacou funkciou, ktorá môže byť napríklad súčasťou post spracovacieho odporúčacieho komponentu (2.1.3), ktorý prahuje filmy smerom ku nedávnym záujmom daného používateľa.

Netflix okrem už spomenutých typov odporúčaní ponúka aj odporúčania založené na novo vydanom obsahu, ktoré sa odlišujú od nedávno pridaných filmov tým, že sú oboje naraz – nedávno vydané aj nedávno pridané. Tieto odporúčania sú takisto personalizované preferenciám používateľa.

Nasledujúci zoznam obsahuje odporúčania filmov, ktoré boli vybraté na základe jedného filmu, ktorý si používateľ v minulosti už pozrel (Obrázok 3.5). Tento zoznam je vygenerovaný použitím objektovo orientovaného kolaboratívneho filtrovania (2.2.1.1.2).

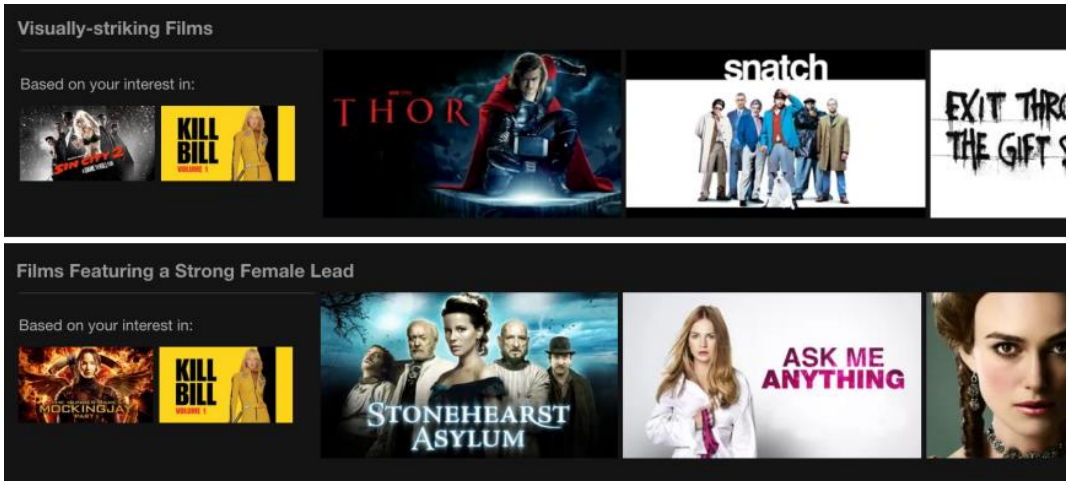

Obrázok 3.6 Odporúčania filmov na Netflix založené na dvoch filmoch pozretých daným používateľom [30]

Ďalšie pásy s odporúčaniami sú podobné tomu predošlému, rozdiel je ale ten, že odporúčania sú vybraté na základe dvoch filmov (Obrázok 3.6). Tieto dva filmy sú zobrazené na začiatku zoznamu, aby používateľ vedel, na základe ktorých filmov mu Netflix odporúča ďalšie filmy obsiahnuté v tomto zozname. Niektoré z týchto zoskupení môžu byť pomenované automatickým popisom, ktorý zodpovedá charakteru filmov v danom zozname.

Netflix ponúka pre svojich odoberateľov početné odporúčania filmov s rôznym charakterom. Kombinácia niekoľkých rozličných odporúčacích algoritmov je rozmiestnená do niekoľkých zoznamov v podobe posuvných pásov na používateľskom rozhraní. Väčšinou si používateľ vyberá film podľa jeho aktuálnej nálady. Vzhľadom na to, že odporúčací systém nepozná momentálnu používateľovu náladu, ponúka mu široký výber filmov založených na odlišných dedukciách, ktoré by mohli pokryť široké spektrum nálad a tak dosiahnuť, aby aspoň jeden z vybraných filmov odpovedal momentálnej vôli používateľa.

3.2.4 Mendeley Suggest

Mendeley Suggest je odporúčací systém článkov určený pre výskumníkov. Je vytvorený tak, aby im napomáhal objavovať nové výskumy na základe ich krátkodobých alebo dlhodobých záujmov a udržiavať ich zbehlých v aktuálnych trendoch týkajúcich sa oblasti ich pôsobenia. Odporúčací systém, ktorý je v ňom implementovaný, popisuje článok [31].

Tým, že zobrazuje odporúčania, ktoré pokrývajú rozdielne prípady použitia, pomáha výskumníkom nachádzať relevantné výskumy, ktoré sú buď pre nich priamo užitočné pri ich práci alebo rozširujú ich obzory.

Prvá skupina odporúčaní je založená na všetkých článkoch, ktoré používateľ vložil do svojej osobnej knižnice v programe Mendeley. Druhý zoznam článkov obsahuje odporúčania založené na činnosti Mendeley komunity. Tieto články sú dôležité v oblasti pôsobenia daného používateľa, ale nemusia nutne zodpovedať jeho aktuálnym záujmom. Takto má používateľ aktuálny prehľad o článkoch, ktoré sú relevantné v širšej oblasti pôsobenia daného používateľa (Obrázok 3.7).

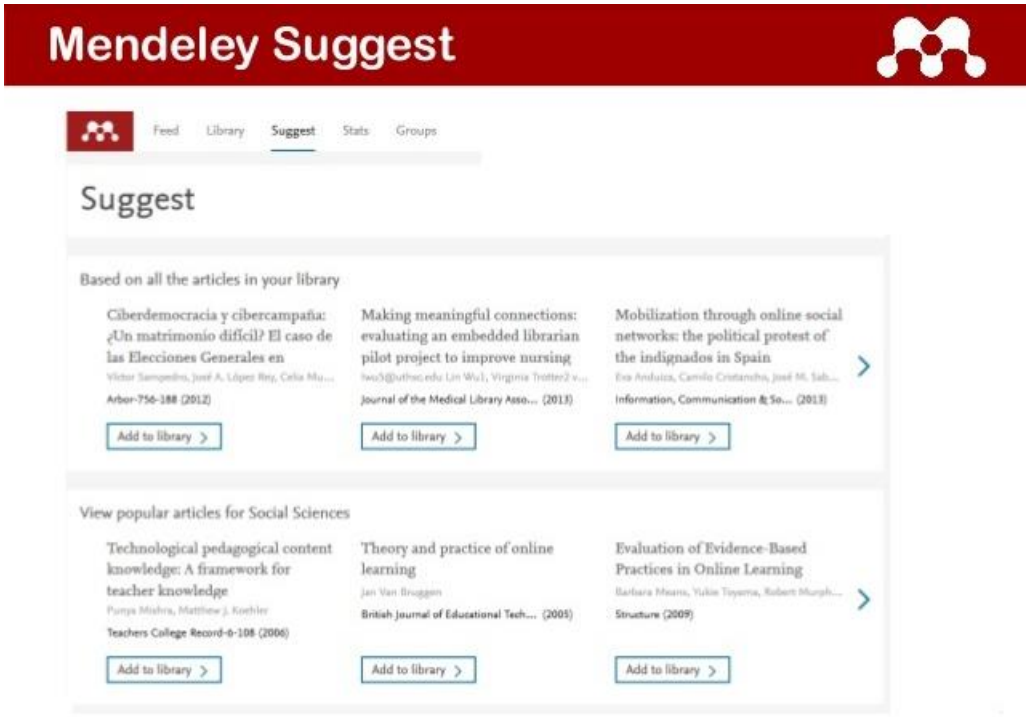

Obrázok 3.7 Náhľad odporúčaní vygenerovaných Mendeley Suggest [32]

Tretia skupina je založená na nedávnej aktivite používateľa. Nachádzajú sa v nej články odporučené na základe naposledy pridaných článkov do používateľovej knižnice. Tento typ odporúčaní sa viac sústreďuje na používateľa a reaguje na jeho meniace sa záujmy.

Štvrtá kolekcia článkov obsahuje odporúčania vybrané na základe posledného článku, ktorý používateľ prečítal prostredníctvom Mendeley nástroja na zobrazovanie dokumentov v pdf formáte. Tieto odporúčania dopĺňajú tie vyššie spomenuté, keďže naposledy pridaný článok do knižnice a naposledy otvorený článok sa môžu líšiť. Táto situácia sa dá ilustrovať na scenári, v ktorom si používateľ najprv vloží do knižnice niekoľko článkov, ktoré bude potrebovať pri svojej nadchádzajúcej práci, a až potom začne s ich čítaním, alebo sa môže vrátiť ku práci, na ktorej nebol nejaký čas aktívny. V tomto prípade odporúčania na základe naposledy pridaných článkov nemusia byť pre neho relevantné, ale odporúčania založené na jeho naposledy prečítanom článku môžu byť nápomocné.

Posledný zoznam obsahuje odporúčania článkov, ktoré sú aktuálne populárne v Mendeley komunite v rámci oblasti pôsobenia daného používateľa. Výber článkov je podobný ako v prípade zoznamu populárnych článkov, avšak sa viac sústreďuje na nedávne trendy vo zvykoch čitateľov v rámci Mendeley komunity.

3.3 Príklady poskytovateľov odporúčacích systémov

3.3.1 Fact-Finder

Podľa informácii čerpaných z [33], Fact-Finder[16] ponúka pre svojich používateľov niekoľko nástrojov uľahčujúcich chod a manažment internetového obchodu. Jeden z týchto nástrojov je odporúčací systém.

Ten analyzuje dáta o predajoch a historické dáta o kliknutiach na elementy stránok, na základe čoho identifikuje relevantné a doplňujúce produkty, ale aj kategórie a atribúty, ktoré sa hodia k vybranému produktu. Okrem toho zohľadňuje jednotlivé interakcie konkrétneho zákazníka s obchodom, jeho pohyby na stránke, obsah košíka a jeho predošlé nákupy, čím sa snaží vytvoriť zákazníkovi odporúčanie na mieru.

Prípadné zmeny v katalógu produktov alebo pridanie nového produktu je okamžite brané do úvahy pri generovaní odporúčaných produktov. Takto systém poskytuje perspektívny predaj nového produktu už od jeho uvedenia do ponuky.

Systém dokáže generovať odporúčania nielen v situácii, kedy vstup do odporúčacieho systému tvorí len jediný produkt, ale aj pre vstup tvorený z viacerých produktov, napríklad z nákupného košíka. V tomto prípade generuje odporúčania tak, aby dopĺňali a vyhovovali produktom z celého košíka (Obrázok 3.8). Napríklad, keď má zákazník v košíku košeľu a kravatu, systém zákazníkovi nenavrhne nákup ďalšej kravaty, ktorá dopĺňa už vloženú košeľu, alebo ďalšej košele, ktorá dopĺňa kravatu, ale vyberie produkt dopĺňajúci oba tieto produkty naraz – napríklad vestu.

3.3.2 econda

econda[17] spracováva denne bilióny dát získaných z internetových obchodov od svojich zákazníkov, ukladá ich, vylepšuje a ponúka okamžité reporty. Odhaduje profily zákazníkov a produkuje odporúčania v reálnom čase. Informácie o odporúčacom systéme poskytovaným týmto prevádzkovateľom sú čerpané zo zdroja [34].

Cross Sell odporúčací systém berie ako vstupy online správanie návštevníkov, aktuálne produkty a interakcie s jednotlivými webovými stránkami v rámci e-shopu. Výsledné odporúčania poskytnuté systémom môžu predstavovať pre zákazníka popud na pridanie ďalších produktov na základe odporúčaní zobrazených na stránke nákupného košíka, na základe individuálnych odporúčaní vo forme newslettera (letáku) alebo zobrazením najnakupovanejších produktov na úvodnej webovej stránke e-shopu. Prevádzkovateľ internetového obchodu si môže prispôsobovať pokrytie odporúčaní na používateľovom rozhraní pomocou určitých pravidiel.

Systém vyberá na odporúčanie tie produkty, ktoré sú najčastejšie predávané spoločne alebo také, ktoré najvodnejšie dopĺňajú už vybrané produkty a skompletizujú outfit. Odporúčania sú navrhované dynamicky na základe zákazníkových interakcií s produktmi.

---

[16] www.fact-finder.com
[17] www.econda.de

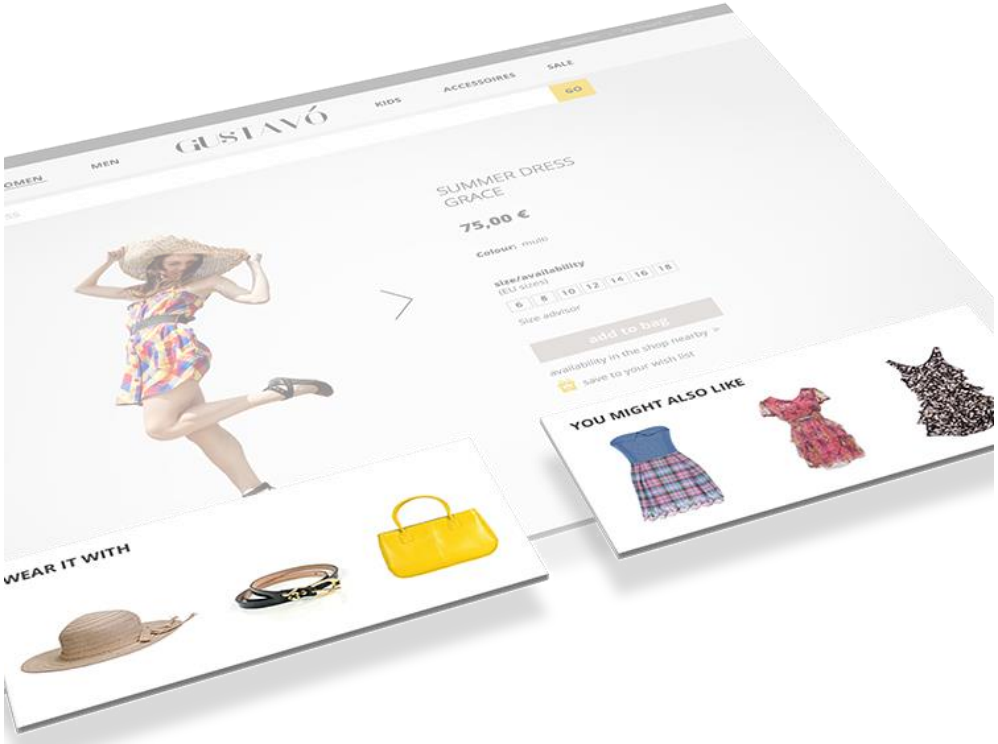

Obrázok 3.8 Príklad odporúčaní generovaných Fact-finder odporúčacím systémom [33]

Audience Relationship Platfrom ponúka vytvorenie personalizovaných odporúčaní. Platforma spracováva dáta z CRM[18] alebo ERP[19] systémov prevádzkovateľa e-shopu, z business intelligence riešení alebo zo skladových dát a pomáha prevádzkovateľovi pochopiť zákazníkove preferencie a potreby. Na základe tejto znalosti môže prevádzkovateľ následne interagovať s každým zákazníkom na individuálnej úrovni.

Personalizované odporúčania sú v kombinácii s Cross Sell systémom vytvárané z informácii získaných zo všetkých zákazníkových zariadení, z dát o jeho offline nákupoch a o jeho preferovaných značkách. Pomocou tejto platformy môže prevádzkovateľ e-shopu filtrovať zákazníkov na cieľové skupiny na základe ich správania sa, a toto rozdelenie následne použiť na odporúčanie produktov a vytvorenie personalizovaného obsahu.

3.3.3 Yoochoose

Yoochoose ponúka pre svojich používateľov SaaS riešenia („*software as service*“, teda software ako služba, je spôsob poskytovania aplikácie, ktorý umožňuje používateľom používať aplikácie cez internet pripojením sa na cloudové úložisko, kde sú uložené [35]), ktoré im napomáhajú vytvoriť personalizovaný prístup ku zákazníkovi v podobe personalizovaných odporúčaní, výsledkov vyhľadávania a newslettrov.

Zakladá si na niekoľkoročných skúsenostiach v oblasti odporúčaní založených na obsahu, ktoré pramenia zo spolupráce medzi laboratóriami Deutche Telekom[20]

[18] customer relationship management
[19] enterprise resource planning
[20] www.telekom.com/de

a univerzitou Ben Gurion[21]. Výsledkom je riešenie, ktoré umožňuje zákazníkom jednoduché vyhľadávanie žiadaných produktov na pozadí komunikácie upravenej zákazníkovi na mieru. Informácie o ňom sú čerpané zo zdroja [36].

Yoochoose poskytuje odporúčací systém, ktorý umožňuje dodávať zákazníkovi personalizované a relevantné odporúčania založené na aktuálnych a historických dátach o správaní sa zákazníka v rámci internetového obchodu. Pomáha vytvárať prostredie prispôsobené konkrétnemu zákazníkovi tak, aby zodpovedalo jeho preferenciám a potrebám. Prevádzkovateľovi daného e-shopu ponúka kompletnú kontrolu nad nastaveniami odporúčacieho systému. Takto si prevádzkovateľ môže prispôsobiť odporúčací systém podľa svojich podnikateľských cieľov.

Odporúčací systém zbiera informácie o prezeraní si stránok e-shopu jednotlivými zákazníkmi, ich kliknutia na konkrétne objekty. Algoritmy strojového učenia využité v tomto systéme sa následne tieto dáta učia a reagujú na zákazníkove preferencie. Systém ponúka niekoľko typov odporúčaní:

- personalizované odporúčanie produktov – systém vyberá tie produkty, ktoré by mohli byť tiež objektom záujmu zákazníka,
- kolaboratívne filtrovanie – systém vyberá produkty na základe podobnosti s ostatnými zákazníkmi, ktoré si prezerali rovnaké produkty ako vybraný zákazník,
- odporúčania založené na zákazníkovom profile – systém vyberá ďalšie produkty z určitej značky,
- obsahovo orientované odporúčania – systém vyberá podobné produkty ako tie, s ktorými zákazník interaguje,
- automatická segmentácia podobnej skupiny zákazníkov ako vybraný zákazník,
- odporúčania založené na najpredávanejších produktoch,
- odporúčania založené na zľavnených produktoch.

Je navrhnutý tak, aby v prípade, že zlyhá jeden z typov odporúčania, napríklad kolaboratívne filtrovanie kvôli nedostatku historických dát o danom zákazníkovi, využijú sa odporúčania iného typu ako najpredávanejšie produkty, čím sa zaručuje, že zákazník vždy dostane kvalitné odporúčania.

Okrem toho môže prevádzkovateľ internetového obchodu vďaka prispôsobiteľným nastaveniam systému označiť nového návštevníka stránky ako zákazníka a aktuálnych zákazníkov ako častých zákazníkov.

[21] in.bgu.ac.il/en/pages/default.aspx

4 Návrh odporúčacieho systému

Rady a kroky pri vytváraní odporúčacieho systému popísané v tejto časti sú čerpané zo zdroja [37].

Na základe tohto zdroja sa návrh odporúčacieho systému obyčajne skladá z 3 zložiek:

1. vytvorenie algoritmu na hodnotenie presnosti systému,
2. určenie prístupu, ktorý bude používaný v systéme,
3. nastavenie parametrov systému.

4.1 Určenie presnosti odporúčacieho systému

Vyhodnotenie odporúčacieho systému je dôležitá časť počas návrhu systému, ktorá napomáha doladiť prístup používaný v systéme, používané parametre alebo dimenzie. Vzhľadom na tento fakt je dôležitým krokom na začiatku celého vyhodnocovacieho procesu stanoviť si, ako sa ohodnocovanie procesu bude uskutočňovať, a je potrebné tento spôsob zachovať konzistentný po celý čas.

V prípade, ak vybraný odporúčací prístup pracuje s náhodne vygenerovanou množinou vzoriek, je dôležité túto množinu použiť niekoľkokrát, čím sa zabezpečí, aby zmeny v presnosti systému neboli spôsobené zmenami v množine testovacích vzoriek. Tak isto je vhodné použiť ako testovacie vzorky takých používateľov, ktorí tvoria reprezentatívnu vzorku v rámci celej množiny používateľov.

Podľa vzoru obchodnej logiky sa pri vyhodnotení vygenerovaných odporúčaní systémom môže zameriavať napríklad na to, či:

- sa odporúčania zhodujú s kategóriami už zakúpených objektov vybraného používateľa,
- cena odporučených objektov spadá do intervalu už zakúpených objektov,
- značka odporúčaného objektu sa vyskytuje medzi už zakúpenými objektmi.

Tieto kritériá je možné skombinovať, čím sa získa skóre pre vygenerované odporúčania z pohľadu viacerých aspektov.

Skórovanie systému je preferované v rozsahu 0 až 1 pre dané odporúčanie, čo umožňuje vyjadriť skóre ako váženú percentuálnu hodnotu. Po získaní takýchto hodnotení úspešnosti systému je vhodné vybrať top *n* skóre odporúčaní pre každého používateľa v testovacej vzorke a spriemerovať výsledok. Výber hodnoty pre parameter *n* by mal byť podmienený počtom očakávaných kvalitných odporúčaní vygenerovaných systémom s ohľadom na dostatočný počet odporučených objektov, ktoré budú prezentované používateľovi.

4.2 Výber prístupu používaného odporúčacím systémom

Ako odporúča autor článku [37], v prvom rade je vhodné preskúmať dostupné dáta a na základe ich vlastností sa pokúsiť vylúčiť nevhodné prístupy pre dané dáta. Ďalej

odporúča po vyfiltrovaní nevhodných prístupov a dopracovaní sa k výberu dvoch prístupov vytvoriť rýchly prototyp oboch systémov, čo napomôže porovnať presnosť odporúčaní generovaných jednotlivými systémami. Takýmto spôsobom je možné získať prehľad o výkone systému, jeho presnosti a o tom, aké typy odporúčaní systém generuje.

Odporúčania generované využitím jedného prístupu môžu byť veľmi podobné objektom, ktoré používateľ ohodnotil v minulosti, zatiaľ čo odporúčania vybrané iným prístupom predstavujú široký výber objektov, ktoré sú stále relevantné, ale nie hneď na prvý pohľad ako v prvom prípade. Ilustrované na príklade používateľa, ktorý nakupuje veľa masla, sa odporúčania môžu týkať iných značiek masla alebo objektov ako chlieb, šunka či vajíčka.

Podľa týchto informácii sa na záver vyberie prístup, ktorý spĺňa požiadavky a ciele prevádzkovateľa vybraného e-shopu, kde má byť odporúčací systém zavedený.

4.3 Nastavenie parametrov systému

Po výbere odporúčacej metódy je často potrebné odladiť parametre systému na dosiahnutie najväčšej presnosti a najlepšieho výkonu systému. Niektoré prístupy, ako napríklad kolaboratívne filtrovanie (2.2.1) má hyperparametre, respektíve parametre, ktoré ovplyvňujú správanie sa odporúčacieho systému a jeho presnosť.

Ich hodnoty je možné získať testovaním presnosti systému vzhľadom na rôzne kombinácie parametrov pomocou hodnotiaceho algoritmu vybraného v prvom kroku návrhu odporúčacieho systému. Vizualizácia skóre systému pri jednotlivých nastaveniach môže uľahčiť výber vhodných parametrov systému nad dostupnými dátami. Hyperparametre systému sú väčšinou nezávislé na sebe, preto môže byť nápomocné skúmať vplyv hodnôt jednotlivých hyperparametrov na výkon systému oddelene.

5 Vyhodnotenie odporúčacieho systému

V oblasti odporúčacích systémov sa predpokladá interakcia používateľov so systémom a tak isto aj s ostatnými používateľmi. Preto je pri vyhodnocovaní odporúčacích systémov možné použiť množstvo metód využívaných vo výskume sociálneho správania, ktoré umožňujú zodpovedať výskumné otázky ako [8]:

- Vnímajú používatelia interakciu s odporúčacím systémom ako užitočnú?
- Sú spokojní s kvalitou prezentovaných odporúčaní?
- Čo motivuje používateľov ponúknuť systému dáta ako ohodnotenie odporúčaní alebo komentáre k nim, a tým zlepšiť kvalitu predikcie systému?
- Čo konkrétne používateľ kladne vníma na získaní odporúčaní? Je to miera serendipity a novosti alebo je to len skutočnosť, že je ušetrený od procesu hľadania odporučených objektov?

V [38] sú popísané 4 metodológie využívané na vyhodnocovanie odporúčacích systémov:

1. offline vyhodnocovanie,
2. prieskum používateľov,
3. štúdia používateľov,
4. online vyhodnocovanie.

5.1 Online vyhodnocovanie

Do online vyhodnocovania odporúčacieho systému sú zapojení reálni používatelia. Umožňuje vyhodnotiť, ako používatelia reálne interagujú s odporúčacím systémom, napríklad, koľkokrát si používateľ vyberie nejaký odporučený objekt vzhľadom na počet všetkých odporučených objektov.

V tomto type vyhodnocovania sa na porovnanie dvoch odporúčacích metód používa takzvané A/B testovanie, ktoré vyžaduje rozdelenie používateľov do dvoch skupín, pričom jednej z nich sa ponúknu odporúčania vygenerované systémom A a druhej skupine odporúčania získané od systému B [38]. Toto rozdelenie sa zvyčajne uskutočňuje presmerovaním malého percenta prevádzky e-shopu na niektorý z testovaných odporúčacích systémov a následne sa zaznamenávajú interakcie používateľov s ním. Presmerovanie by malo prebiehať náhodne, aby sa zabezpečili rovnaké podmienky pre testované systémy [39].

Tak isto je dôležité uvedomiť si, ktoré aspekty odporúčacieho systému sú vyhodnocované. Ak sa vyhodnocovanie zameriava na presnosť systému, používateľské rozhranie by malo byť zafixované pre oba systémy. Naopak, ak sa vyhodnocovanie sústreďuje na používateľské rozhranie, zafixovaný by mal byť odporúčací algoritmus.

Online vyhodnocovanie odporúčacieho systému je obyčajne veľmi nákladné. Navyše, pri návrhu odporúčacieho systému je väčšinou snaha nájsť jeho slabiny predtým, ako je zavedený do e-shopu. V opačnom prípade sa totižto môže stať, že používateľovi budú prezentované pre neho nerelevantné objekty, čo ho môže odradiť od využívania

odporúčacieho systému. Z týchto dôvodov je vhodné, aby bol odporúčací systém vyhodnotený najprv v offline podmienkach, pričom sa predpokladá, že výsledky získané počas offline vyhodnocovania budú odpovedať reálnemu nasadeniu systému do e-shopu [39].

5.2 Offline vyhodnocovanie

V prípade offline vyhodnocovania je potrebné simulovať reálny proces, v ktorom systém odhaduje, ktoré objekty by mohli byť užitočné pre používateľa a v ktorom ich používateľ následne využíva. Tieto podmienky sú obyčajne dosiahnuté získaním historických dát o správaní existujúcich používateľov v rámci daného e-shopu, pričom môžu obsahovať informácie o explicitnej alebo implicitnej spätnej väzbe.

Na vstupe do systému sa nachádza množina vybraných profilov používateľov, ktoré obsahujú ohodnotenia objektov. Jednotlivé profily sa počas vyhodnocovania rozdelia na dve časti, a to na ohodnotenia, ktoré budú tvoriť trénovaciu množinu predstavujúcu vstup do systému, a ohodnotenia, ktoré budú využité ako testovacia množina na vyhodnotenie odporúčaní vygenerovaných systémom [8][39].

V [8] sú spomenuté dve metódy, ktorými môže byť inšpirované rozdelenie profilov:

- „all but N“ – je daná fixná hodnota premennej *N* určujúcej veľkosť testovacej množiny u každého používateľa.
- „given N“ – je daná fixná hodnota premennej *N* určujúcej veľkosť trénovacej množiny u každého používateľa.

Vyhodnotenie odporúčacieho systému sa podľa charakteru historických dát môže zameriavať na predikčnú alebo klasifikačnú schopnosť odporúčacieho systému. Predikčná úloha sa zaoberá odhadom chýbajúcich ohodnotení v matici preferencií. V prípade klasifikačnej úlohy sa zoberie *n* objektov z množiny objektov, ktoré systém považuje za relevantné pre používateľa, pričom sú vyberané podľa skóre, ktoré im udal samotný odporúčací systém. Následným vyhodnotením týchto odporúčaní vzhľadom na skryté, testovacie dáta, môžeme získať jeden zo štyroch možných výsledkov načrtnutých v Tabuľka 5.1 [8][1].

Tabuľka 5.1 Klasifikácia možných výsledkov odporučených objektov používateľovi [1]

	odporučené systémom	**neodporučené systémom**
preferované používateľom	skutočne pozitívne (TP)	falošne negatívne (FN)
nepreferované používateľom	falošne pozitívne (FP)	skutočne negatívne (TN)

Skutočne pozitívny výsledok sa týka odporučeného objektu, ktorý je reálne preferovaný používateľom, falošne pozitívny nastáva v prípade, kedy je objekt odporučený systémom, ale znalosť o preferovaní tohto objektu vybraným používateľom nie je známa, a falošne negatívny sa týka prípadu, kedy je objekt preferovaný používateľom, ale odporúčací systém ho neodporučil [40].

Zoznam odporúčaní prezentovaných používateľovi väčšinou obsahuje tri až desať objektov, keďže používatelia zvyčajne nemajú tendenciu prechádzať dlhšie zoznamy [8].

5.2.1 Metriky na vyhodnotenie odporúčacieho systému na základe historických dát

V [8] je spomenutých niekoľko metrík, ktoré sú často používané pri vyhodnocovaní odporúčacieho systému operujúceho nad historickými dátami.

5.2.1.1 Presnosť predikcie

Na vyhodnotenie schopnosti systému predikovať používateľove preferencie pre vybraný objekt sa najčastejšie používajú numerické merania chyby, ako „mean absolute error“ (MAE), „root mean squared error“ (RMSE) alebo normalizované MAE (NMAE) [40].

MAE vyjadruje strednú odchýlku medzi vypočítanými ohodnoteniami odporúčaní $rec(u,i)$ a skutočnými ohodnoteniami $r_{u,i}$ pre všetkých používateľov $u \in U$ obsiahnutých v testovacej množine $testset_u$. Formálne [8]:

$$MAE = \frac{\sum_{u \in U} \sum_{i \in testset_u} \left| rec(u,i) - r_{u,i} \right|}{\sum_{u \in U} \left| testset_u \right|}. \tag{5.1}$$

Okrem toho sa využíva aj normalizované MAE (NMAE), ktoré zohľadňuje rozsah hodnôt ohodnotení, teda

$$NMAE = \frac{MAE}{r_{max} - r_{min}}, \tag{5.2}$$

kde r_{max} a r_{min} vyjadrujú najvyššiu a najnižšiu hodnotu ohodnotení, čím sa NMAE normalizuje do intervalu 0 až 1.

5.2.1.2 Presnosť klasifikácie

Pri predikcii objektov ako relevantné alebo nerelevantné sa mení úloha odporúčania objektov na binárnu klasifikáciu. V tomto prípade je možné využiť pri ohodnocovaní metriky využívané v „information retrieval“ (vyhľadávanie informácii) ako „precision“ alebo „recall“ [40].

Tie sú prirodzenejšie v kontexte odporúčacích systémov, keďže v reálnej interakcii je používateľovi reprezentovaný zoznam odporučených objektov a nie odhady ich ohodnotení [8].

S využitím Tabuľka 5.1 je v [1] precision a recall definované nasledovne:

$$Precision = \frac{\#TP}{\#TP + \#FP} \tag{5.3}$$

$$Recall = \frac{\#TP}{\#TP + \#FN} \tag{5.4}$$

Precision vyjadruje teda pomer medzi počtom správne odporučených objektov a celkovým počtom odporučených objektov, pričom recall vyjadruje pomer medzi počtom správne odporučených objektov a teoretickým maximom správne odporučených objektov, zodpovedajúcej veľkosti testovacej množiny [8].

5.2.1.3 Presnosť rankingu objektu

Ranking objektov odporúčacím systémom sa chápe ako výsledné usporiadanie objektov vybraných na odporúčanie vzhľadom na ich skóre, ktoré im bolo priradené systémom počas výpočtového procesu. Ranking objektu teda zodpovedá pozícii vybraného objektu v zozname odporúčaní vygenerovaných systémom.

Pri využití tejto metriky sa nezohľadňuje len to, či objekt bol správne odporučený, ale aj jeho relatívna pozícia v zozname odporúčaní [8].

5.2.2 Recall-coverage multiobjektívne vyhodnocovanie

Autori článku [40] navrhujú na vyhodnocovanie odporúčacieho systému použiť recall-coverage multiobjektívne vyhodnocovanie. Nimi navrhnutý prístup používa pri vyhodnocovaní systému okrem metriky recall aj dodatočné meranie založené na „catalog coverage“, čím sa vyhodnocovanie systému mení na multiobjektívny optimalizačný problém.

5.2.2.1 Catalog coverage

Catalog coverage vyjadruje, aké percento dostupných objektov systém odporúča používateľom [41]. Je definovaný ako pomer medzi počtom rôznych objektov, ktoré systém odporučil používateľom tvoriacim testovaciu sadu, a celkovým počtom objektov, ktoré systém môže použiť na odporúčanie, teda celkový počet rôznych objektov ponúkaných v rámci daného e-shopu. Formálne [40]:

$$catalog_coverage(model) = \frac{|\{TopN(model, u) | u \in U_{test}\}|}{|I|} \tag{5.5}$$

Pri využití metódy vyhodnocovania odporúčacieho systému, kedy sa z historických dát vybraného používateľa vyberie jeden objekt do testovacej množiny a ostatné tvoria vstup do systému ako trénovacia množina, majú odporúčacie systémy tendenciu odporúčať často nakupované objekty v rámci daného e-shopu. Systém týmto spôsobom síce môže dosiahnuť vysokú presnosť, ale hodnota coverage bude nízka a používateľovi nebudú odporučené nové alebo zaujímavé objekty, ktoré by si za normálnych okolností nevšimol [40].

Navrhované recall-coverage multiobjektívne vyhodnocovanie sa skladá z množiny X predstavujúcej množinu všetkých testovaných modelov, napríklad model využívajúci rovnakú odporúčaciu metódu s rozdielnym nastavením parametrov, a z dvoch objektívnych funkcií - f_{rec} a f_{cov}, ktoré sú skúmané na rovnakej sade dát.

Podľa definície v [40] sa model m označuje ako pareto-dominujúci modelu $\hat{m}$ vtedy, ak spĺňa aspoň jednu z podmienok:

- $f_{rec}(m) > f_{rec}(\widehat{m}) \wedge f_{cov}(m) \geq f_{cov}(\widehat{m})$, teda model m dosahuje vyššiu hodnotu recall ako $\widehat{m}$ a jeho hodnota catalog coverage je prinajmenšom taká dobrá ako $\widehat{m}$,
- $f_{cov}(m) > f_{cov}(\widehat{m}) \wedge f_{rec}(m) \geq f_{rec}(\widehat{m})$, teda model m má vyššiu hodnotu catalog coverage ako $\widehat{m}$ a jeho hodnota recall je prinajmenšom taká dobrá ako $\widehat{m}$.

Experimenty prevedené v článku navrhujúcom tento prístup preukázali, že na základe výsledkov online testovania boli najúspešnejšie tie systémy, ktoré sa nachádzali v centre pareto frontu výsledkov offline testovania. Na základe tohto záveru navrhujú optimalizovať parametre odporúčacieho algoritmu využitého v systéme v zmysle maximalizovania harmonického priemeru recall a coverage meraní, formálne:

$$RC_{hm} = 2 \cdot \frac{recall \cdot catalog_coverage}{recall + catalog_coverage}. \tag{5.6}$$

6 Analýza problému a návrh metodológie riešenia

Ako už bolo spomenuté v úvode, úlohou diplomovej práce je preskúmať ponúknuté dáta a zvoliť vhodný odporúčací model na generovanie odporúčaní nad týmito dátami. V nasledujúcich častiach bude popísaná analýza získaných dát, zvolený odporúčací systém a vyhodnocovací systém použitý na vyhodnotenie a výber odporúčacieho modelu a jeho parametrov vhodných pre dané dáta.

6.1 Analýza dát z e-shopu Kickz

Pre účel tejto diplomovej práce boli ponúknuté dáta z e-shopu Kickz[22]. Jedná sa o nemecký internetový obchod, ktorý ponúka svojim zákazníkom produkty zväčša športového charakteru. Na vykonanie experimentov bol použitý dump produkčnej databázy vytvorený 9.10.2017.

Štruktúru tejto databázy tvorí 212 tabuliek a sekvencií. Okrem aktuálnych dát sa tu nachádzajú aj historické dáta ukladané od začiatku sprístupnenia obchodu na internete.

Kickz má niekoľko verzií e-shopu diferencovaných jednak podľa domén, ale aj biznis logiky. Každá z týchto verzií má pridelený vlastný identifikátor, ktorý je zadaný prevádzkovateľom e-shopu.

Po registrácii sa do e-shopu dostane každý zákazník svoj jednoznačný identifikátor, ktorý je generovaný použitím sekvencie a využívaný ako cudzí kľúč v ďalších tabuľkách databázy.

Čo sa týka produktov e-shopu, každý z nich má tri úrovne:

- *product* – najvšeobecnejšia abstrakcia produktu, zahŕňa produkt so všetkými variáciami farieb a ich jednotlivých veľkostí,
- *product color variant* – diferencuje jednotlivé farebné prevedenia produktu a tie v sebe zahŕňajú veľkosti ponúkané v danej farbe,
- *product variant* – najnižšia a najkonkrétnejšia úroveň produktu, obsahuje konkrétne veľkosti konkrétnych farieb vybraného produktu.

Tabuľka 6.1 ilustruje jednotlivé úrovne produktu na konkrétnom prípade. Keď má zákazník záujem o nejaký produkt, napríklad taký, ktorý ho zaujme na zobrazenej stránke katalógu, po kliknutí na jeho obrázok je presmerovaný na stránku detailu produktu. Na stránke sa okrem údajov o danom produkte nachádza aj zoznam obrázkov zobrazujúcich jednotlivé farebné prevedenia daného produktu – tento zoznam obsahuje dostupné *product color varianty*. Ďalej sa tu nachádza zoznam ponúkaných veľkostí. Po výbere veľkosti kliknutím na žiadanú veľkosť má vybraný produkt úroveň *product variantu*.

[22] www.kickz.com

Tabuľka 6.1 Ilustrácia abstrakcie produktu v e-shope Kickz

Produkt	Úroveň abstrakcie produktu
Tričko značky Puma	product
Tričko značky Puma, farba: modrá	product color variant
Tričko značky Puma, farba: modrá, veľkosť: L	product variant

Informácie o úrovniach produktov sú uložené v samostatných tabuľkách. Každý *product* má pridelený jednoznačný identifikátor generovaný sekvenciou, ktorý je použitý ako cudzí kľúč v tabuľkách ostatných úrovní, kde každý záznam má tak isto jedinečný identifikátor. Jedná sa ale len o interný identifikátor v rámci databázy – pre účely biznis logiky e-shopu je využívané SKU (stock keeping unit), skladové číslo priradené produktu prevádzkovateľom internetového obchodu.

Jednotlivé úrovne produktov obsahujú aj rozličné atribúty definujúce danú úroveň. Výber niektorých atribútov dostupných priamo z tabuliek úrovní produktov alebo spojením s inými popisuje Tabuľka 6.2.

Tabuľka 6.2 Vybrané atribúty jednotlivých úrovní produktov

Úroveň produktu	Názov atribútu	Popis atribútu
product	product_id	jednoznačný identifikátor
	sku	skladové číslo
	brand_id	identifikátor značky produktu
product color variant	product_color_variant_id	jednoznačný identifikátor
	sku	skladové číslo
	shop_id	variant e-shopu
	gender	pohlavie, pre ktoré je produkt určený
	color	farebné prevedenie
	material	materiál
	short_description	krátky popis produktu
	long_description	dlhý popis produktu
	category	kategória produktu
product variant	product_variant_id	jednoznačný identifikátor
	sku	skladové číslo
	price	cena
	online	označuje, či produkt je momentálne ponúkaný zákazníkom

Produkty môžu patriť do niekoľkých kategórii, pričom tieto kategórie sú podľa miery všeobecnosti rozdelené do dvoch úrovní.

Kickz ponúka svojím zákazníkom nákupy ako registrovaní používatelia alebo ako anonymní používatelia. Táto skutočnosť je rozlíšená prítomnosťou jednoznačného identifikátora zákazníka v tabuľke obsahujúcej informácie o danej objednávke, ktorá obsahuje okrem iných atribútov aj dátum vytvorenia. Položky obsiahnuté v jednotlivých objednávkach sú v ďalšej tabuľke. Záznamy položiek obsahujú informácie ako SKU produktu, identifikátor verzie obchodu, kde bol zakúpený, a niektoré atribúty popisujúce daný produkt.

6.2 Popis vybraného odporúčacieho systému

Na generovanie odporúčaní nad databázou e-shopu Kickz som si vybrala odporúčací systém Recombee[23]. Tento systém je vyvíjaný v spolupráci s akademickými partnermi Českým vysokým učením technickým v Praze[24] a Data Science Laboratory[25].

Ku odporúčaciemu systému sa pristupuje prostredníctvom RESTful API a podporuje viacero programovacích jazykov ako Ruby, Java, Python či .NET. Odporúčania sú ponúkané v reálnom čase, pričom Recombee dokáže spracovať viac ako 500 odporúčaní za sekundu bez ohľadu na vyťaženosť e-shopu jeho zákazníkmi.

Okrem platenej verzie ponúka Recombee pre svojich používateľov možnosť vytvoriť si bezplatný účet. K nemu následne získa používateľ prístup ku svojej databáze na serveri Recombee, ktorý je tvorený identifikátorom databázy a tajným prístupovým tokenom. Tieto údaje sú využívané pri komunikácii s Recombee prostredníctvom API. Používateľ okrem toho získa prihlasovacie údaje do grafického rozhrania svojej databázy, kde si môže zobraziť dáta uložené v Recombee databáze, a takisto štatistické údaje o odporúčaniach vyžiadaných z Recombee a interakciách vložených do Recombee databázy. Umožňuje vkladať interakcie ako:

- nákup objektu (purchases),
- pozretie objektu (views),
- ohodnotenie objektu (ratings),
- pridanie objektu do košíka (cart additions),
- záložky (bookmarks).

Interakcia je definovaná identifikátorom používateľa, identifikátorom objektu a časovou stopou definujúcou čas vzniku danej interakcie. Typ interakcií je diferencovaný pri exporte dát do databázy, kedy sa pre každý typ využíva iná metóda.

Náhľad do databázy je tvorený klasickým tabuľkovým zobrazením, pričom je rozdelený na dve časti – objekty a používatelia. V oboch tabuľkách je možnosť rýchleho vyhľadávania, ktorý umožňuje nájdenie objektu alebo používateľa podľa jeho identifikátora. Po kliknutí na identifikátor objektu sa zobrazí tabuľka zobrazujúca zoznam identifikátorov používateľov, ktorí interagovali s týmto objektom. Pre každý typ

[23] www.recombee.com
[24] www.cvut.cz
[25] datalab.fit.cvut.cz

interakcie je zobrazený samostatný zoznam, pričom sa dá medzi zoznamami prepínať. Pre používateľov existuje obdobná možnosť, zoznam je ale tvorený identifikátormi objektov.

Recombee umožňuje posielanie viacerých requestov naraz s využitím batch requestu, čo uľahčuje export väčšieho množstva dát, napríklad pri iniciálnom vkladaní dát do databázy.

Na výber sú dva typy odporúčacích metód:

- používateľsky orientované odporúčania – požiadavka na odporúčanie pre vybraného používateľa,
- objektovo orientované odporúčania – požiadavka na odporúčania objektov, ktoré sú podobné vybranému objektu, pričom môžu byť brané do úvahy aj informácie o používateľovi za účelom vytvorenia personalizovaných odporúčaní.

Jadro celého odporúčacieho systému tvorí niekoľko odporúčacích metód, ktoré sú naďalej zdokonaľované s využitím umelej inteligencie.

6.3 Popis vybraného vyhodnocovacieho systému

Na vyhodnocovanie odporúčaní generovaných systémom Recombee s využitím dát e-shopu Kickz som sa rozhodla použiť aplikáciu vyvinutú v rámci diplomovej práce Ing. Josefa Dvořáka [42], ktorá umožňuje offline vyhodnocovanie systému Recombee.

Táto aplikácia priamo komunikuje s API Recombee systému a umožňuje vytvorenie niekoľkých testov, v rámci ktorých je možné otestovať rôzne odporúčacie modely s rôznymi parametrami nad vybranou sadou dát.

Testy môžu byť spustené buď s náhodným výberom vzoriek z dát používateľov uložených v databáze Recombee alebo s množinou vzoriek vytvorených používateľom tohto vyhodnocovacieho systému, pričom sú tieto informácie získavané z lokálnej databázy. Vzorky sú tvorené pármi používateľ-objekt.

Testovanie prebieha tak, ako je popísané v časti 5.2. Náhodne vybrané vzorky alebo vzorky načítané z databázy tvoria testovaciu časť profilov vybraných používateľov. Systém postupne prechádza jednotlivé vzorky a pri každom používateľovi vymaže príslušné interakcie s objektom, ktorý tvorí testovaciu časť vzorky. Zvyšné interakcie sú následne použité pri generovaní odporúčaní pre daného používateľa. Získané odporúčania sú zapísané do databázy a testovaný objekt je naspäť uložený do Recombee databázy.

Aplikácia ponúka nasledujúci výber odporúčacích modelov obsiahnutých v systéme Recombee:

- UserkNN model – názov tohto modelu referuje na používateľsky orientované kolaboratívne filtrovanie, ktoré využíva kosínusovú podobnosť.
- Ranking Item kNN model – model je podobný ako UserKnn, používa ale objektovo orientovaný prístup.
- Token Item kNN model – využíva obsahovo orientovanú odporúčaciu metódu používajúcu kosínusovú podobnosť medzi objektmi.

- Asociačné pravidlá – objavujú skryté patterny v dátach, určité vzťahy medzi jednotlivými objektmi, a tým napomáhajú odhadnúť používateľovo správanie. Jedná sa o implikáciu v tvare $X \rightarrow Y$, kde $X \cap Y = \emptyset$ [43]. Sila asociačného pravidla je vo všeobecnosti meraná v zmysle „support“ a „confidence“, v Recombee systéme je využívaný len „support“, ktorý určuje, ako často je vybrané pravidlo aplikovateľné na danej množine dát.
  Asociačné pravidlo $X \rightarrow Y$ je podporované v systéme, ak spĺňa

$$\frac{|\{T \in U \mid X \cup Y \in T\}|}{|U|} \geq s_{min} \tag{6.1}$$

  kde $s_{min} \in [0.0,1.0]$ je „minimal support“, T je transakcia a U je množina všetkých transakcií používateľov.

Modely využívané v Recombee používajú takzvaný popularity-biasing parameter β [40], ktorý reguluje odporúčanie populárnych objektov v rámci daného e-shopu. Odporúčanie najčastejšie nakupovaných objektov totižto spôsobuje nízku hodnotu coverage, no použitie parametra β penalizujúceho populárne objekty dáva šancu na odporúčanie aj menej často ohodnocovaným objektom, čo zvyšuje rôznorodosť v navrhovaných objektoch, a teda aj hodnotu coverage.

Popularita určitého objektu *i* v modeloch systému Recombee je vyrátaná ako

$$popularity(i) = \sum_{u \in U} \left(r_{u,i} - \overline{r_u}\right) \tag{6.2}$$

kde $r_{u,i}$ je ohodnotenie daného objektu určitým používateľom a $\overline{r_u}$ je priemerná hodnota všetkých ohodnotení daného používateľa. Takto získaná popularita objektu sa použije pri regulovaní ranku odhadnutého odporúčacím systémom $rank(u,i)$:

$$rank_{PS}^{\beta}(u,i) = \frac{rank(u,i)}{popularity(i)^{\beta}} \tag{6.3}$$

kde $\beta \epsilon [0.0, 1.0]$.

Aplikácia po prejdení všetkých testovaných párov umožňuje vyhodnotenie testov s využitím metriky navrhnutej v práci [40], pričom má používateľ aplikácie možnosť si dať tieto výsledky vizuálne zobraziť, čo mu napomáha pri výbere optimálnych parametrov vybraného modelu.

6.4 Návrh metodológie vyhodnocovania

V experimentálnej časti diplomovej práce som sa rozhodla zamerať na niekoľko odporúčacích modelov obsiahnutých v rámci odporúčacieho systému Recombee a vybrať ten, ktorý bude na základe offline vyhodnocovania dosahovať najlepšie výsledky.

Experimenty budú vykonané s použitím nasledujúcich modelov:

- UserkNN model,
- Ranking Item kNN,
- Token Item kNN.

Prvý model som si vybrala na základe mojich informácií zistených počas prípravy teoretickej časti tejto práce, kde som sa vo viacerých zdrojoch dočítala, že tento model patrí medzi najpoužívanejšie odporúčacie metódy. Testovaním druhého modelu chcem zistiť, či sa moje výsledky budú zhodovať so skúsenosťami tvorcov Recombee systému, kde, ako sa vyjadrili v článku [44], používateľsky orientované kolaboratívne filtrovanie prekonalo objektovo orientované pri viacerých databázach aj scenároch.

Vzhľadom na fakt, že kolaboratívne filtrovanie využíva na odporúčanie historické dáta o interakciách používateľov, pri spomenutých modeloch a používateľoch so žiadnymi alebo iba niekoľkými takýmito dátami môže vzniknúť cold start problém popísaný v časti 2.3. Vyhodnocovanie tretieho modelu má za úlohu zistiť možnosti Recombee systému v situáciách, kedy:

- používateľ nemá žiadne historické dáta o interakciách alebo len veľmi málo,
- vybraný objekt nemá žiadne interakcie s používateľmi alebo len veľmi málo.

Vyhodnotenie vybraných modelov bude vykonané s využitím vyhodnocovacieho systému popísaného v časti 6.3, kde požiadavky na odporúčania budú posielané do Recombee systému s rôznymi hodnotami parametrov z vopred vybraného intervalu hodnôt. Správanie modelu bude skúmané pri meniacich sa hodnotách nasledovných parametrov:

- popularity-biasing parameter β – popísaný v časti 6.3, parameter regulujúci odporúčanie najviac nakupovaných objektov, pre potreby experimentov som sa rozhodla použiť lineárne rastúce hodnoty z intervalu $\beta \epsilon [0.0, 1.0]$.
- kknn – hodnota tohto parametra určuje počet najpodobnejších používateľov/objektov (záleží od typu odporúčacieho modelu), ktoré sa vyskytnú vo výbere objektov vhodných na odporúčanie pre vybraného zákazníka. Rozhodla som sa použiť exponenciálne rastúce hodnoty pre otestovanie väčšieho rozsahu hodnôt tohto parametru.

Vyhodnocovanie prvého modelu bude pre porovnanie vykonané na oboch úrovniach objektov – *product color variant* a *product*. Predpokladám, že úroveň *product* bude vhodnejšia na odporúčania, keďže dáva systému väčšiu voľnosť vzhľadom na všeobecnosť tejto úrovne, a tým pádom má aj väčšiu šancu na správne odhadnutie objektu v testovacej vzorke. Podľa môjho názoru nie je dôležité objekty diferencovať na farby, ale dôležitejší je druh samotného objektu z pohľadu atribútov ako kategória alebo značka. Informáciu o farbe by som napríklad použila v prípade, kedy by som chcela zobraziť odporúčania na informačnej stránke objektu. Vtedy by som v zozname odporúčaní zobrazila používateľovi odporúčania v takej farbe, akú má práve zobrazovaný objekt. Pri použití Token Item kNN sa zase môže stať, že pri použití úrovne *product color variant* označí odporúčací systém identický objekt vzhľadom na úroveň *product* a tieto objekty sa budú líšiť len vo farbe, čo považujem za nežiaduce správanie. Cieľom využitia

odporúčacieho systému je používateľovi ponúknuť nové objekty, nie ten istý objekt v inej farbe.

Zvolený vyhodnocovací systém bol prispôsobený na dáta z práce [42], kde interakcie boli typu pozretia (views). Po niekoľkých konzultáciách s tvorcom systému Josefom Dvořákom bol tento vyhodnocovací systém doplnený o ďalšie interakcie a testovanie bolo prispôsobené pre potreby experimentov v rámci tejto diplomovej práce. Vzhľadom na charakter získaných dát z e-shopu Kickz, kde historické dáta obsahujú informácie o interakciách typu nákup (purchases), používa vyhodnocovací systém iba tento typ interakcie.

Ako bolo spomenuté v časti 6.3, vyhodnocovací systém využíva recall-coverage metriku popísanú v práci tvorcov Recombee systému [40]. Inšpirovaná touto prácou použijem pri výbere vhodného modelu rovnaký spôsob výberu, teda za vhodné hodnoty parametrov modelu budem považovať tie, ktoré sa budú nachádzať v centre pareto frontu výsledkov offline testovania a budú maximalizovať hodnotu harmonického priemeru recall a coverage RC_{hm} podľa vzťahu 5.6.

Pri modeli Token Item kNN sa okrem vhodného výberu parametrov sústredím aj na výber vhodnej množiny atribútov objektov. Preto spustím niekoľko testov s rovnakým rozsahom hodnôt pre parametre *kknn* a β, ale nad rozdielnou množinou atribútov objektov.

Na základe výsledkov obsiahnutých v práci [40] autori popísali spozorované správanie testovaných modelov (používateľsky orientovaný k-NN a acociatívne pravidlá), kedy vyššia hodnota parametru *k* (počet najpodobnejších používateľov) znižovala hodnotu recall aj coverage. Pri vysokej hodnote *k* sa odporúčanie produktov podobá na odporúčanie populárnych objektov, pričom recall je v prípade odporúčania najpredávanejších objektov zvyčajne vysoký. Nízke hodnoty *k* zase vedú k nízkym hodnotám recall spôsobených javu zvanému overfitting (situácia, kedy sa model príliš presne nafituje na ponúknuté vzorky). Coverage ale s klesajúcou hodnotou *k* narastal.

Vplyv hodnôt parametru β záviselo na prispôsobivosti modelu. Pri modeloch s vysokou prispôsobivosťou, teda modeloch s nižšou hodnotou *k*, β redukovala recall a zvyšovala coverage.

Popri vyhodnocovaní výsledkov sa pokúsim zhodnotiť, či sa moje zistenia budú približovať vyššie popísaným pozorovaniam.

7 Experimenty

7.1 Výber atribútov objektov a predspracovanie dát

Na základe analýzy dát popísanej v časti 6.1 som sa rozhodla vybrať a otestovať nasledujúce atribúty produktov:

- identifikátor
- značka,
- kategória,
- pohlavie,
- farba,
- materiál,
- krátky popis,
- dlhý popis.

S využitím programu SQL Workbench a PostgreSQL drivera som si z pôvodných tabuliek v databáze e-shopu Kickz vyextrahovala potrebné informácie a uložila do nových tabuliek. Tie som následne vyexportovala ako txt dokumenty, ktoré tvorili zdroje pri exporte dát do databázy Recombee.

S atribútmi produktov pracuje len model Token Item kNN. Z dôvodov, ktoré som spomenula v časti 6.4, použijem na účely vyhodnocovania úroveň objektov *product*.

Ako ukazuje Tabuľka 6.2, väčšina žiadaných atribútov je obsiahnutá na úrovni *product color variant*. Získanie atribútov pre úroveň *product* vyžadovalo vytvorenie viacerých dotazov v jazyku SQL a niektoré potrebovali aj dodatočné spracovanie, ako napríklad odstránenie zavádzajúcich informácii v atribúte dlhý popis (zoznam veľkostí, informácie obsiahnuté v ďalších atribútoch, cena, atď.). Pri viacerých hodnotách krátkeho popisu alebo dlhého popisu som sa rozhodla tieto hodnoty spojiť do jedného stringu. Ako jednoznačný identifikátor produktov som zvolila identifikátor použitý v pôvodnej databáze.

Tabuľka 7.1 Zoznam zvolených atribútov objektov úrovne *product* a ich typov

Názov atribútu	Typ atribútu	Poznámka
Identifikátor	String	jednoznačný identifikátor
Značka	String	každý produkt má len 1 značku
Kategória	Set	produkt môže patriť do viacerých kategórii
Pohlavie	String	Možné hodnoty: M – mužské, F – ženské, U – univerzálne N – neutrálne.

Farba	Set	produkt môže mať viac ako len jeden farebný variant
Materiál	Set	zloženie produktu sa môže skladať z viacerých materiálov
Krátky popis	String	
Dlhý popis	String	

Pre používateľov som zvolila jediný atribút a to jednoznačný identifikátor, ktorý je podobne ako v prípade objektov rovnaký ako v pôvodnej databáze.

Do databázy boli pre každého používateľa vložené informácie o interakciách typu nákup, kde každá táto interakcia sa skladá z jednoznačného identifikátora používateľa, jednoznačného identifikátora objektu a časovej stopy vzniku interakcie.

7.2 Export dát do databázy Recombee

Export dát bol vytvorený využitím API klienta pre programovací jazyk Java[26]. Na komunikáciu som využila metódy obsiahnuté v dokumentácii koncových bodov API[27] a v dokumentácii Recombee klienta v jazyku Java[28]. Jednotlivé dáta som načítavala z príslušných txt súborov.

Vyhodnocovanie Token Item kNN vyžadovalo viacnásobný export dát objektov pri meniacich sa atribútoch použitých pri testovaní. Preto som okrem sekvenčného exportu vyskúšala aj paralelný export dát.

Paralelný export dát predstavovalo odosielanie niekoľkých paralelných požiadaviek typu batch obsahujúcich najprv atribúty používateľov, potom objektov a nakoniec interakcií typu nákup. Tento spôsob síce urýchlil celkový čas potrebný na export dát, ale vyskytovali sa pri ňom technické problémy, ktoré ovplyvňovali výsledky testov v podobe prázdnych odporúčaní pre používateľov.

Po konzultácii s vývojármi Recombee som sa rozhodla ostať pri sekvenčnom exporte dát, kde sa najprv odošle batch pre dáta používateľov, po jeho spracovaní pre objekty a nakoniec pre interakcie. Použitie rozdielnych atribútov pri modeli Token Item kNN bolo docielené opakovaným exportom atribútov objektov, kde nežiaduce atribúty mali prázdne hodnoty a tým pádom neboli daným algoritmom brané do úvahy.

7.3 Spôsob vytvorenia testovacej vzorky

Histogramy zobrazené na Obrázok 7.1 a Obrázok 7.2 popisujú rozdelenie používateľov podľa počtu rôznych nakúpených objektov, pričom sú rozdelené podľa úrovne objektov.

[26] dokumentácia je dostupná na: docs.recombee.com/java_client.html
[27] docs.recombee.com/api.html
[28] docs.recombee.com/_static/java/index.html

Pre obe úrovne som sa rozhodla vytvoriť vybalansovanú testovaciu sadu dát s veľkosťou 1000 testovacích párov používateľ-objekt, pričom som sa rozhodla, že každý používateľ sa v testovacích párochvyskytne iba raz. Vzhľadom na spôsob testovania som do testovacej množiny nezaraďovala používateľov s jedným zakúpeným produktom.

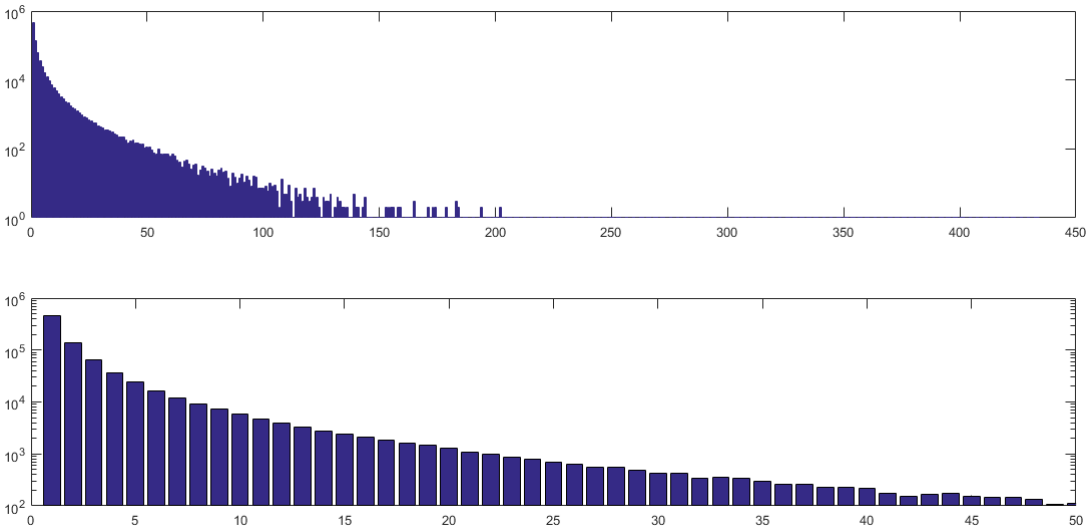

Obrázok 7.1 Histogram zobrazujúci početnosť používateľov podľa množstva zakúpených produktov úrovne *product color variant* z historických dát

Testovacia sada nad úrovňou *product color variant* bola vytvorená používateľmi do 51 zakúpených produktov, čo vychádza na každú skupinu používateľov podľa počtu produktov 20 testovacích párov. Používatelia patriaci pod určitú skupinu používateľov budú vyberaní náhodne, tak isto ako aj objekt z ich nakúpených produktov, ktorý bude tvoriť testovací pár s daným používateľom.

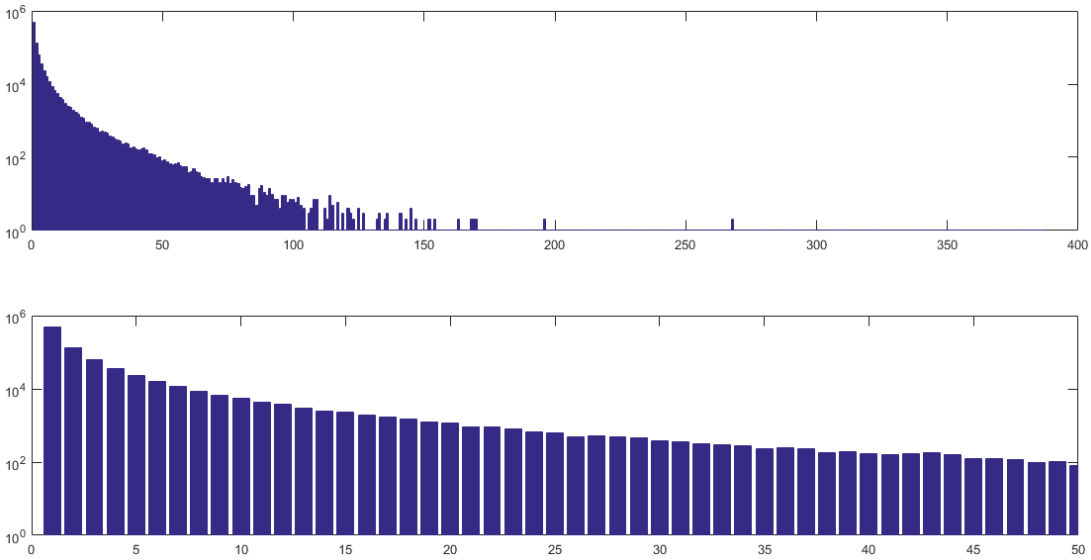

Obrázok 7.2 Histogram zobrazujúci početnosť používateľov podľa množstva zakúpených produktov úrovne *product* z historických dát

Pre úroveň *product* som použila rovnaký postup s použitím používateľov do 41 zakúpených produktov, čiže 25 testovacích párov pre každú skupinu.

Test modelu UserkNN model bol navyše vyhodnotený s použitím testovacej množiny o veľkosti 10 000 používateľov, kde jednotlivé vzorky boli z dát o interakciách vyberané náhodne.

7.4 Výsledky experimentov

V každom teste sa od modelu vyžadovalo vygenerovanie 5 odporúčaných objektov a hodnoty parametru β boli vyberané z intervalu $\beta \epsilon [0.0, 1.0]$.

Čo sa týka hodnôt coverage, celkovo sa v databáze nachádzalo 469 549 objektov úrovne *product color variant* (PCV). Pri testovacej vzorke 1000 používateľov a pri počte 5 žiadaných odporúčaných objektov mohol systém celkovo odporučiť 5000 rôznych objektov. S využitím vzorca 5.5 tak dostávame maximálnu možnú hodnotu $\mathrm{coverageP}\mathrm{CV}_{max} = 0.0106$.

Pri objektoch úrovne *product* (P) sa v databáze nachádzalo celkovo 39 514 objektov, teda s rovnakými podmienkami dostávame $\mathrm{coverageP}_{max} = 0.1265$.

Na ilustráciu odporúčaní z jednotlivých vyhodnotení boli vybraní 3 používatelia z testovacích vzoriek s počtom nakúpených objektov 2, 3 a 4. Popis odporučených objektov vygenerovaných jednotlivými modelmi s parametrami, ktoré dosiahli najlepší výsledok na základe vyhodnotenia, sa nachádza v Príloha B .

7.4.1 UserkNN model

Najprv som spustila testy nad databázou, v ktorej sa vyskytovali objekty na úrovni *product color variant*. Pri nižších hodnotách parametru *kknn* sa vo výsledkoch objavil značný počet prázdnych odporúčaní pre určité testovacie vzorky. Pri *kknn* = 5 sa jednalo až o 425 testovacích vzoriek z celkových 1000, pri *kknn* = 40 to bolo 179 vzoriek, pri *kknn* = 427 sa zredukoval tento počet na 12. Až pri hodnote *kknn* = 1171 bol odporúčací systém schopný vygenerovať odporúčania pre celú testovaciu vzorku.

Po preskúmaní testovacích vzoriek, pri ktorých systém vrátil prázdne odporúčania, bolo zistené, že sa väčšinou jednalo o používateľov, pri ktorých buď neexistovali interakcie s ich zvyšnými produktmi, ktoré tvorili trénovaciu vzorku pre systém, alebo tieto interakcie existovali, no používatelia z nich mali buď značne vyšší počet rozdielnych nakúpených objektov, alebo nemali interakciu s inými objektmi ako s porovnávaným používateľom, alebo tvorili jeho podmnožinu.

Pre porovnanie bol spustený test s rovnakou testovacou vzorkou, ale nad dátami, kde objekty boli úrovne *product*. Vzhľadom na výsledky prvého testu som sa zamerala na hodnoty *kknn* Є [156,4500]. Systém bol schopný v tomto prípade vygenerovať odporúčania pre celú testovaciu vzorku pri *kknn* = 4500.

Posledný test sa týkal tak isto dát s objektmi úrovne *product*, tentokrát bola ale použitá vybalansovaná testovacia vzorka a hodnoty *kknn* Є [1,6300]. S prázdnymi odporúčaniami sa dokázali vysporiadať modely s *kknn* > 3214.

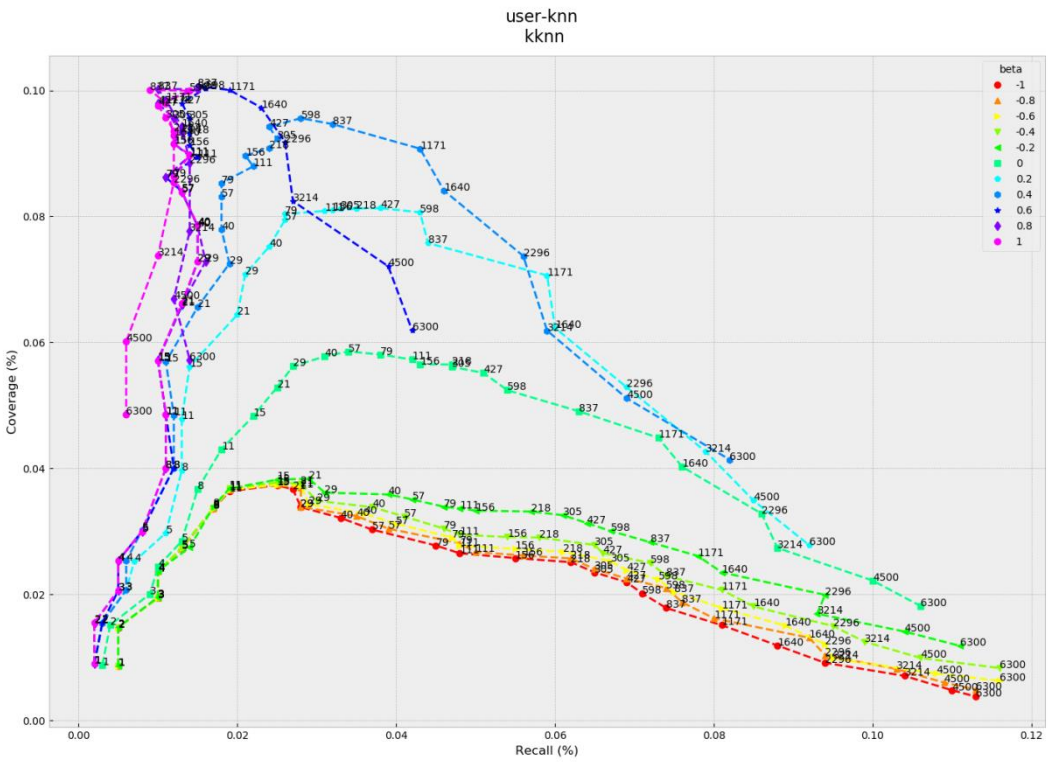

Obrázok 7.3 Graf získaných hodnôt recall a coverage počas vyhodnocovania modelu UserkNN nad dátami s objektmi úrovne *product* s vybalansovanými testovacími dátami

Pri objektoch úrovne *product color variant* (Obrázok A.1) dosiahol najvyššiu hodnotu $\max(recall) = 0.045$ model s parametrami *kknn* = 4500 a β = 0.4, kde hodnota *coverage* bola 0.00615. Najvyššiu hodnotu $\max(coverage) = 0.00912$ dosiahol model s parametrami *kknn* = 427 a β = 0.6, kde hodnota *recall* bola 0.014. Zo získaných výsledkov považujem za vhodného kandidáta model s parametrami *kknn* = 1171 a β = 0.4, kde *recall* = 0.036 a *coverage* = 0.00731.

Nad objektmi úrovne *product* (Obrázok A.2) mal najvyššiu hodnotu $\max(recall) = 0.056$ model s parametrami *kknn* = 4500 a β = 0.2, kde hodnota *coverage* bola 0.03547. Najvyššiu hodnotu $\max(coverage) = 0.10047$ dosiahol model s parametrami *kknn* = 837 a β = 0.8, kde hodnota *recall* bola 0.007. Zo získaných výsledkov považujem za vhodných kandidátov model s parametrami *kknn* = 2296 a β = 0.4, kde *recall* = 0.038 a *coverage* = 0.07504, model s parametrami *kknn* = 837 a β = 0.2, kde *recall* = 0.037 a *coverage* = 0.07612, a model *kknn* = 1171 a β = 0.2, kde *recall* = 0.04 a *coverage* = 0.07162.

Porovnaním výsledkov je zrejmé, že model dosahuje lepšie výsledky nad oboma úrovňami od *kknn* > 300. Z hľadiska hodnôt *coverage* vzhľadom na $coverage_{max}$ dosajú lepšie hodnoty modely operujúce nad úrovňou *product color variant*, no vyššie hodnoty *recall* boli dosiahnuté nad úrovňou *product*.

Čo sa týka posledného testu (Obrázok 7.3), $\max(recall) = 0.116$ mal model s parametrami *kknn* = 6300 a β = -0.4, kde hodnota *coverage* bola 0.0083. Najvyššiu hodnotu $\max(coverage) = 0.1007$ dosiahol model s parametrami *kknn* = 837 a β = 0.6, kde hodnota *recall* bola 0.015. Vhodných kandidátov s ich parametrami

a získanými hodnotami popisuje Tabuľka 7.2. Na základe výsledkov bol najlepší model s parametrami *kknn* = 1171 a β = 0.2.

Po bližšej analýze bolo zistené, že tento model vygeneroval menej ako 5 žiadaných odporúčaní pre celkovo 40 používateľov z 1000 v testovacej vzorke.

Tabuľka 7.2 Vhodní kandidáti pre UserkNN model

kknn	beta	recall	coverage	RC_{hm}
1171	0.4	0.043	0.09075	0.05835
1640	0.4	0.046	0.08412	0.05948
2296	0.4	0.056	0.07372	0.06365
1171	**0.2**	**0.059**	**0.07063**	**0.06429**
1640	0.2	0.060	0.06231	0.05988

Z výsledkov zobrazených na Obrázok 7.3 je zrejmé, že hodnota *coverage* najprudšie narastala pri nižších hodnotách *kknn,* kedy β Є [0.2,1], teda v prípadoch penalizácie populárnych produktov. Tento jav je podľa mňa prirodzený, keďže penalizáciou populárnych produktov sa systém môže zamerať na širšiu škálu zdrojových produktov. Pri týchto hodnotách tak isto narastala hodnota *recall*, ale nie s výraznejšími rozdielmi medzi jednotlivými hodnotami.

Od hodnôt *kknn* > 500 sa ale hodnota *coverage* začala znižovať, no hodnota *recall* začala výraznejšie narastať. Zvyšujúcimi sa hodnotami *kknn* má systém k dispozícii širšiu skupinu používateľov, a teda sa neupína len na malú, konkrétnu skupinu. So širšou skupinou používateľov sa tak isto začne viac zameriavať na častejšie nakupované produkty. Podľa môjho názoru narastajúce hodnoty *recall* mohli byť ešte ovplyvnené aj tým, že sa pri týchto hodnotách *kknn* výrazne začal znižovať aj počet prázdnych odporúčaní. Zaujímavé je ale správanie modelu pri hodnotách β = 1 a β = 0.8, kedy začali klesať aj hodnoty *coverage* aj hodnoty *recall*.

Pri postupnom preferovaní populárnych produktov, kedy β Є [-1,-0.2] dosahoval *coverage* omnoho nižšie hodnoty a nárast týchto hodnôt nebol taký výrazný, pričom sa začal znižovať už približne pri hodnotách *kknn* > 21 . Modely s týmito hodnotami parametra β dosiahli ale najlepšie hodnoty *recall*. Z pohľadu hodnôt oboch parametrov sa ale výsledky modelov pri meniacich hodnotách parametrov *kknn* nelíšili tak výrazne, ako pri predošlých hodnotách parametra β.

Z výsledkov môžem usúdiť, že pre tento model sú nad danými dátami najvhodnejšie hodnoty parametrov β = 0.2 a β = 0.4 a *kknn* Є [500,3000].

7.4.1.1 Vyhodnotenie UserkNN modelu s testovacou množinou o veľkosti 10 000 vzoriek

V rámci modelu UserkNN bol spustený ešte jeden test nad dátami, kde objekty boli úrovne *product*, testovacia množina v tomto prípade bola ale veľkosti 10 000 testovacích párov používateľ-objekt. Tento test slúžil na názornejšie znázornenie správania sa jednotlivých modelov vzhľadom na meniace sa hodnoty parametrov β a *kknn*.

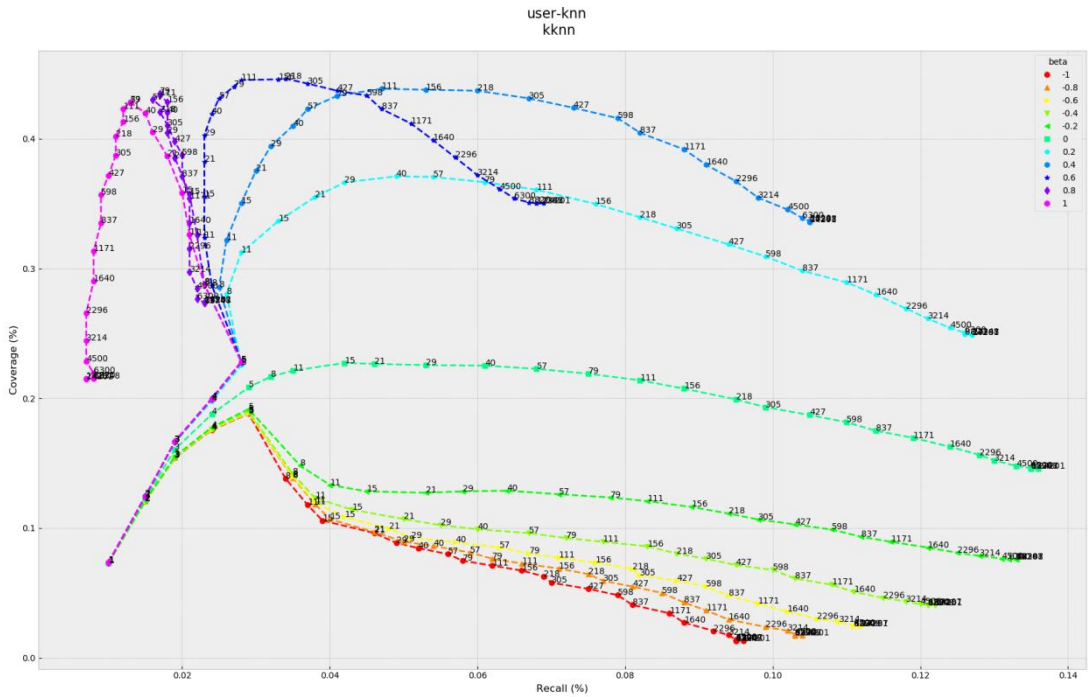

Obrázok 7.4 Graf získaných hodnôt recall a coverage počas vyhodnocovania modelu UserkNN nad dátami s objektmi úrovne *product* s testovacou množinou o veľkosti 10 000 vzoriek z pohľadu parametra *kknn*

Ako ukazujú výsledky zobrazené na Obrázok 7.4, nárast hodnôt *coverage* a *recall* pri nízkych hodnotách *kknn*, teda *kknn* Є [1,5], mal rovnaký charakter pri všetkých hodnotách parametra β. Zvyšovaním *kknn* sa ale tento charakter začali líšiť – pri modeloch s hodnotami parametra β Є [0.2,1] penalizujúcimi odporúčania populárnych objektov hodnoty *coverage* prudko narastali, zatiaľ čo pri modeloch, kde β Є [-1,-0.2], začali hodnoty *coverage* klesať.

Modely s hodnotami parametra β Є [0.8;1] preukázali opäť zaujímavé správanie pri hodnotách *kknn* > 80, kedy začali klesať hodnoty *coverage* aj *recall*.

Hodnoty *recall* sa po hodnotách parametra *kknn* ≥ 6300 už výraznejšie nemenili, pričom najväčšiu hodnotu recall dosiahli modely s β Є [0,0.2], kde *kknn* ≥ 4500.

Na základe týchto výsledkov je teda zrejmé, že meniace sa hodnoty parametra β dokázali zvyšovať hodnotu *coverage* pri nízkych hodnotách *kknn* alebo pri β Є [0.2,1], kedy boli odporúčania populárnych objektov penalizované. Pri hodnotách β Є [-1,-0.2] a narastajúcich hodnotách *kknn* systém jednak začal preferovať populárne objekty na základe β, a tak isto sa zameriaval na väčší záber používateľov, čím sa dostávali do popredia často nakupované objekty, a teda sa zvyšovala hodnota *recall* a hodnota *coverage* sa nemenila alebo mierne znižovala.

Nad danými dátami je teda z hľadiska kompromisu medzi hodnotami *recall* a *coverage* podľa môjho názoru najvhodnejšie skúmať modely s hodnotami pre parameter β z intervalu [0.2,0.6] a *kknn* z intervalu [10,4500].

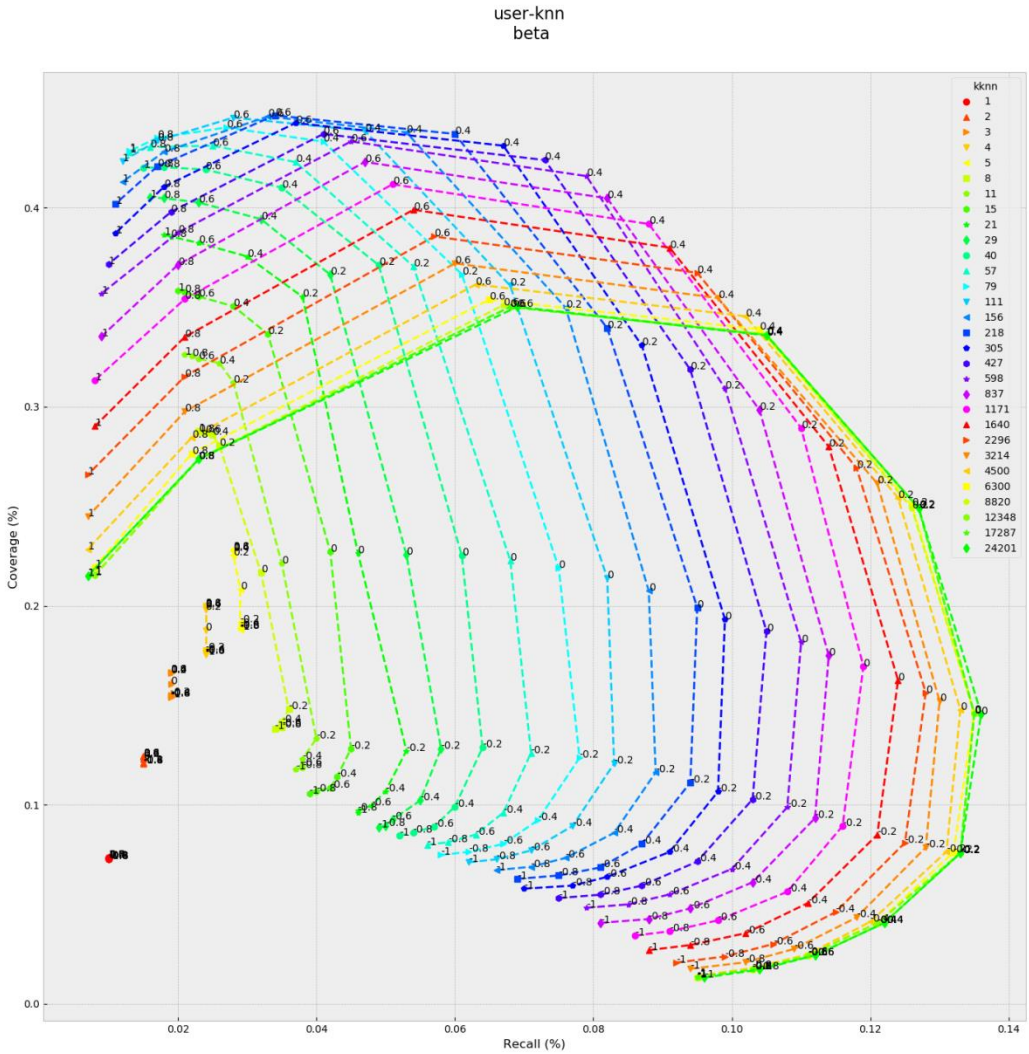

Obrázok 7.5 Graf získaných hodnôt recall a coverage počas vyhodnocovania modelu UserkNN nad dátami s objektmi úrovne *product* s testovacou množinou o veľkosti 10 000 vzoriek z pohľadu parametra *beta*

7.4.2 Ranking Item kNN model

Vyhodnocovanie modelu Ranking Item kNN bolo spustené nad dátami, kde objekty boli úrovne *product* a hodnoty *kknn* Є [0,4500]. Pri tomto type modelu sa nevyskytoval tak markantný problém s prázdnymi odporúčaniami ako pri predošlom type, prázdne odporúčania boli pri meniacich sa parametroch vygenerované pre 2-4 používateľov.

Z výsledkov vyhodnocovania (Obrázok 7.6) dosiahol najvyššiu hodnotu $\max(recall) = 0.123$ model s parametrami *kknn* = 427 a β = -1, kde hodnota *coverage* bola 0.00597. Najvyššiu hodnotu $\max(coverage) = 0.08205$ dosiahol model s parametrami *kknn* = 5 a β = 0.8, kde hodnota *recall* bola 0.027. Podľa výsledkov v Tabuľka 7.3 maximalizuje hodnotu RC_{hm} model s parametrami *kknn* = 598 a β = 0. Tento model vygeneroval menej ako 5 žiadaných odporúčaní pre 9 používateľov.

Tabuľka 7.3 Vhodní kandidáti pre Ranking Item kNN model

kknn	beta	recall	coverage	RC_{hm}
2	0.2	0.040	0.06851	0.05051
11	0	0.048	0.06304	0.054501
21	0	0.053	0.06195	0.057127
57	0	0.060	0.0593	0.059648
598	**0**	**0.069**	**0.05725**	**0.062578**

Z výsledkov zobrazených na Obrázok 7.6 môžem usúdiť, že hodnoty *coverage* aj *recall* sa výraznejšie menili pri nižších hodnotách *kknn.* Pri penalizovaní populárnych objektov, teda pri hodnotách parametru β Є [0.2,1], dosahoval model najvyššie hodnoty *coverage*, no najnižšie hodnoty *recall*. Navyše, pri hodnotách približne *kknn* > 5 sa vyskytla podobná situácia ako v prípade predošlého modelu, klesať začali klesať obe hodnoty – *recall* aj *coverage*.

Preferovaním populárnych produktov hodnotami β Є [-0.4,-1] hodnota *coverage* klesala už pri najnižších hodnotách parametra *kknn*. Tieto modely ale opäť dosahovali najväčšie hodnoty *recall*.

Podľa dosiahnutých výsledkov usudzujem, že pre tento typ modelu nie sú potrebné také vysoké hodnoty *kknn* ako pri predošlom modeli, postačujúce sú hodnoty *kknn* < 600. Čo sa týka parametru β, volila by som hodnoty β = -0.2 alebo β = 0 .

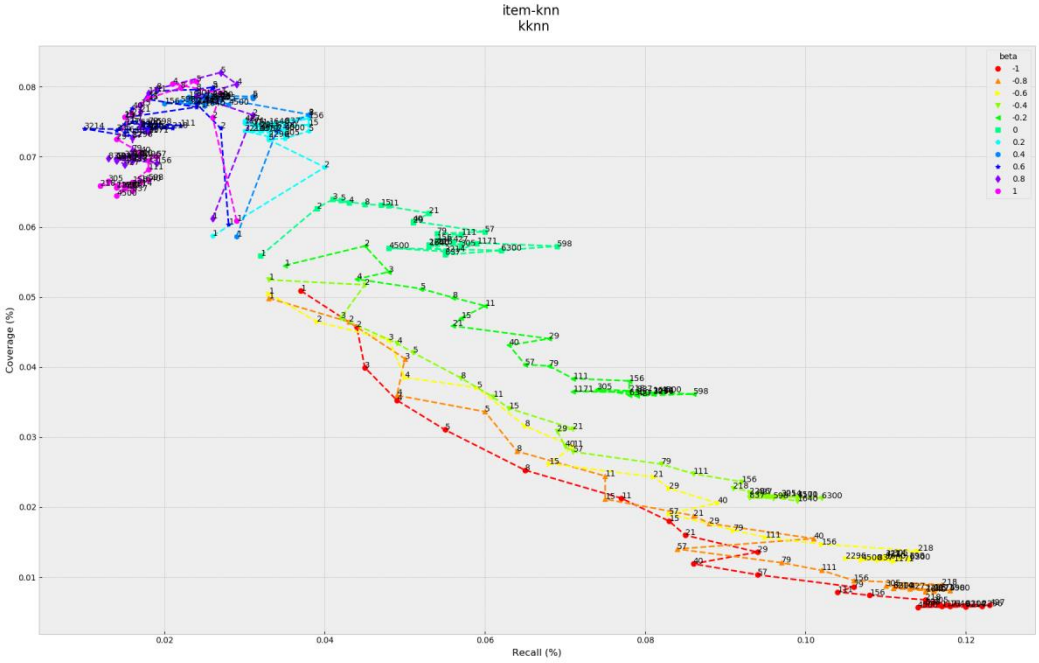

Obrázok 7.6 Graf získaných hodnôt recall a coverage počas vyhodnocovania modelu Ranking Item kNN nad dátami s objektmi úrovne *product*

Porovnaním výsledkov získaných v rámci testovania UserkNN modelu a Ranking Item kNN model je zrejmé, že v prvom prípade boli dosiahnuté vyššie hodnoty *coverage* aj *recall*, pričom prvý model dosahoval lepšie výsledky aj z pohľadu maximalizácie hodnoty RC_{hm}. Na základe toho teda môžem zhodnotiť, že, podobne ako bolo spomenuté v článku [44], model UserkNN využívajúci používateľsky orientované

kolaboratívne filtrovanie svojimi výsledkami prekonal model Ranking Item kNN využívajúci objektovo orientované kolaboratívne filtrovanie.

7.4.3 Token Item kNN model

Cieľom vyhodnocovania Token Item kNN modelu bolo nájsť takú kombináciu zvolených atribútov a hodnôt parametrov modelu, ktoré budú dosahovať najlepšie výsledky vyhodnocovania, teda maximalizovať hodnotu RC_{hm}.

Nad vybranými kombináciami atribútov objektov som otestovala modely s hodnotami parametra *kknn* Є [0,4500]. Atribúty použité v jednotlivých testoch popisuje Tabuľka 7.4. Modely maximalizujúce hodnotu RC_{hm} v rámci jednotlivých vyhodnoteniach sú zobrazené v Tabuľka 7.5.

Tabuľka 7.4 Zoznam vyhodnotení Token Item kNN modelu

Identifikátor testu	Kombinácia testovaných atribútov
Test01	značka, kategória, pohlavie, farba, materiál, krátky popis, dlhý popis
Test02	značka, kategória, pohlavie
Test03	značka, kategória, pohlavie, krátky popis
Test04	značka, kategória, pohlavie, farba
Test05	značka, kategória, pohlavie, farba, krátky popis
Test06	značka, kategória, pohlavie, materiál
Test07	značka, kategória, pohlavie, materiál, krátky popis
Test08	značka, kategória, pohlavie, farba, materiál, krátky popis

Tabuľka 7.5 Parametre modelov maximalizujúcich RC_{hm} a získané výsledky recall a coverage počas testov Token Item kNN modelu

Identifikátor testu	kknn	β	recall	coverage	RC_{hm}
Test01	40	-0.6	0.031	0.05568	0.03982
Test02	305	-0.2	0.036	0.03439	0.03518
Test03	8	-0.2	0.028	0.05396	0.03687
Test04	29	-0.4	0.022	0.04439	0.02942
Test05	8	-0.4	0.027	0.06856	0.03874
Test06	837	-0.2	0.042	0.04024	0.04110
Test07	**8**	**-0.6**	**0.037**	**0.0534**	**0.04371**
Test08	111	-0.2	0.030	0.062	0.04043

Na prvý test som použila všetky vybrané atribúty produktov, ďalšími testami som skúmala vplyv jednotlivých kombinácii produktov na hodnoty *recall* a *coverage*.

Po analýze niekoľkých odporučených produktov z testu *Test01* vzhľadom na trénovaciu vzorku vybraných používateľov som si všimla, že systém sa najviac zameriaval na značku, kategórie, materiál a krátky popis. Dlhý popis vzhľadom na jeho rozsah u niektorých produktov nebol vždy užitočný. Systém sa niekedy upriamil na slovo, ktoré nie úplne výstižne charakterizovalo produkt z testovacej časti vzorky, a teda podobné produkty na základe tohto slova neboli relevantné.

Porovnaním výsledkov z testu *Test01* zobrazených na Obrázok A.3 a testu *Test02* zobrazených na Obrázok A.4 je zrejmé, že kombinácia atribútov použitých v *Test02* dosahovala vyššie hodnoty *recall,* ale hodnoty *coverage* klesli takmer o polovicu. Výrazne lepšie hodnoty recall v prípade testu *Test02* vytiahli výslednú hodnotu harmonického priemeru RC_{hm}. Pridaním atribútu *krátky popis* v teste *Test03* (Obrázok A.5) sa výrazne zvýšili hodnoty *coverage*, hodnoty *recall* boli o čosi menšie. Správanie modelov s meniacimi sa hodnotami *kknn* a β zostalo podobné ako v teste *Test02,* jedine v prípade hodnôt β ∈ [0.2,1] sa hodnoty *recall* a *coverage* s narastajúcim *kknn* znižovali.

Test04 pridal k atribútom z testu *Test02* atribút *farba*. Výsledky zobrazené na Obrázok A.6 ukazujú, že pridaním atribútu sa mierne zvýšili hodnoty *coverage*, hodnoty *recall* sa ale naopak, mierne znížili. Pri modeloch s hodnotami parametra β ∈ [0.2,1] a nízkych hodnotách *kknn*, *kknn* < 25, hodnota *coverage* aj *recall* narastala, no pri ďalších hodnotách *kknn* sa hodnoty už výraznejšie nemenili.

Kombinácia atribútov z *Test02* s atribútom *krátky popis* dosahovala lepšie výsledky ako s atribútom *farba*, preto som skúsila oba tieto atribúty pridať v teste *Test05*, čím som dosiahla zvýšenie oboch hodnôt, *recall* aj *coverage* (Obrázok A.7).

V teste *Test06* som sa zamerala na vplyv pridania atribútu *materiál* ku atribútom použitým v teste *Test02*. Výsledky zobrazené na Obrázok A.8 ukazujú, že hodnoty *coverage* boli o niečo nižšie ako v prípade atribútov *farba* alebo *krátky popis*, hodnoty *recall* boli porovnateľné ako v prípade atribútu *krátky popis*, výraznejšie rozdiely sa prejavili v správaní sa modelov s β ∈ [-1,-0.2]. Vzhľadom na maximalizáciu RC_{hm} dosiahla táto kombinácia lepšie výsledky ako farba a krátky popis.

Test *Test07* pridal ku materiálu krátky popis. Výsledky na Obrázok A.9 ukazujú, že sa tým zvýšila hodnota *coverage* a tak isto aj *recall*, najmä pri modeloch β ∈ [-1,-0.8]. V prípade hodnôt β ∈ [0.2,1] sa s narastajúcim *kknn* hodnota *coverage* znižovala. Táto kombinácia parametrov dosiahla najlepší výsledok v rámci predošlých testov v zmysle maximalizácie RC_{hm}.

Posledný test *Test08* spája všetky vyššie spomenuté atribúty dokopy. Pridaním atribútu *farba* sa zvýšili hodnoty *coverage* a mierne znížili hodnoty *recall*. Zmenilo sa správanie modelov β ∈ [0.2,1], kedy hodnoty *coverage* narastali do približne *kknn* ≤ 5, potom začali klesať. Kombinácia týchto atribútov ale neprekonala výsledky kombinácie z predošlého testu.

Po zhrnutí všetkých výsledkov môžem vyhodnotiť, že v prípade modelu Token Item kNN dosahovali najlepšie výsledky modely s hodnotami parametra β ∈ [-1,-0.2], čo je presným opakom predošlých dvoch testovaných modelov. Modely s nižšími hodnotami parametra *kknn* ≤ 15 a β ∈ [-1,-0.2] dosahovali najvyššie hodnoty *coverage*,

s narastajúcimi hodnotami *kknn* sa *coverage* začala znižovať. Najvyššie hodnoty *recall* dosahovali modely s *kknn* = 4500 a β Є [-1;-0.8].

Problém s prázdnymi odporúčaniami, ktorý sa vyskytol v prípade prvých dvoch testovaných modelov, sa v prípade tohto modelu nevyskytol pri žiadnej kombinácii parametrov.

Na základe výsledkov zaznamenaných v Tabuľka 7.5 dosiahla z hľadiska maximalizácie RC_{hm} najlepší výsledok kombinácia atribútov *značka*, *kategória*, *pohlavie*, *materiál* a *krátky popis* s hodnotami parametrov modelu *kknn* = 8 a β = -0.6.

7.5 Diskusia výsledkov a výber najvhodnejšieho modelu a jeho parametrov

V rámci vyhodnocovaní navrhnutých v tejto diplomovej práci som otestovala celkovo tri modely vybraného odporúčacieho systému Recombee – UserkNN model, Ranking Item kNN model a Token Item kNN model. Tabuľka 7.6 zobrazuje parametre testovaných modelov maximalizujúcich RC_{hm} a v Príloha B sú názorne ilustrované odporúčania vygenerované týmito modelmi.

Ako som už zhodnotila v časti 7.4.2 , výsledky modelu UserkNN prekonali Ranking Item kNN model. Výsledky testovania Token Item kNN modelu dokázali, že systém by bol schopný generovať rozumné odporúčania aj v prípade používateľov so žiadnymi alebo len niekoľkými historickými dátami o interakciách s objektmi. Tak isto by bol schopný poradiť si s novo pridaným objektom do e-shopu s nízkym počtom dát o interakciách s týmto objektom. Na základe výsledkov môžem podľa môjho názoru zhodnotiť, že atribúty objektov obsiahnutých v produkčnej databáze sú po navrhnutých úpravách postačujúce na získanie rozumných odporúčaní.

Tabuľka 7.6 Parametre modelov maximalizujúcich RC_{hm} a získané výsledky recall a coverage počas všetkých testov navrhnutého vyhodnocovania

Model	kknn	beta	recall	coverage	RC_{hm}
UserkNN	**1171**	**0.2**	**0.059**	**0.07063**	**0.064293**
Ranking Item kNN	598	0	0.069	0.05725	0.062578
Token Item kNN	8	-0.6	0.037	0.0534	0.04371

Na základe výsledkov v Tabuľka 7.6 usudzujem, že z hľadiska maximalizácie RC_{hm} je najvhodnejší model UserkNN. Pri výsledkoch testov tohto modelu bolo ale spozorované, že pri niektorých používateľoch systém generuje prázdne odporúčania.

Aby sa predišlo tomuto problému, výsledný odporúčací systém pre e-shop Kickz by som zvolila kombináciou modelov UserkNN a Token Item kNN, kde odporúčania z Token Item kNN modelu by dopĺňali situácie, kedy by UserkNN nebol schopný vygenerovať odporúčania alebo by vygeneroval nižší počet odporúčaní ako by bolo

od neho žiadané. Token Item kNN model by bol tak isto užitočný v prípade cold start problému. Parametre týchto modelov by som vyberala na základe výsledkov v Tabuľka 7.6.

Po analýze ilustrovania vygenerovaných odporúčaní v časti Príloha B som si ale všimla, že zvolený Token Item kNN sa až príliš upínal na jeden typ produktov. Nastala aj situácia, kedy pre používateľa, ktorý mal v historických dátach výlučne interakcie s objektmi, ktoré mali hodnotu atribútu *pohlavie* = „M“, systém odporučil objekty, kde *pohlavie* = „F“. Toto správanie považujem za nežiaduce.

Z týchto dôvodov som preskúmala vygenerované odporúčania najlepšieho modelu z testu nad atribútmi *značka*, *kategória*, *pohlavie*, *materiál*. V tomto prípade boli odporúčané objekty rôznorodejšie a správne z hľadiska hodnoty atribútu *pohlavie*. Táto rýchla analýza sa týkala ale len troch vybraných používateľov, preto by som si tieto hodnoty ešte potvrdila na väčšom množstve používateľov z testovacej množiny.

Vyriešenie problému s hodnotami atribútu *pohlavie* by som vyriešila buď udaním väčšej priority tomuto atribútu alebo by som využila Recombee Query Language (ReQL)[29], ktorým by som vytvorila filtrovanie objektov na základe želanej hodnoty atribútu *pohlavie*.

[29] docs.recombee.com/reql.html

8 Záver

Cieľom tejto diplomovej práce bolo preskúmať súčasné riešenia problematiky odporúčacích systémov a ich vyhodnocovaní a tieto zistenia následne použiť pri návrhu odporúčacieho systému pre e-shop Kickz.

Počas vypracovania tejto práce som si naštudovala informácie o jednotlivých metódach využívaných v odporúčacích systémoch, pričom sa zamerala na ich možnosti nad jednotlivými typmi vstupných dát. Tak isto som preskúmala aktuálne prístupy vyhodnocovania týchto systémov a zamerala som sa na metriky používané v rámci nich. Získané poznatky som zhrnula v teoretickej časti tejto práce. Do práce som taktiež pridala prehľad konkrétnych riešení týchto systémov vo vybraných e-shopoch spoločne s niekoľkými príkladmi súčasných poskytovateľov odporúčacích systémov.

Získané teoretické poznatky som využila v analytickej časti tejto práce, kde som preskúmala dáta ponúknuté od e-shopu Kickz a zhodnotila ich možnosti v rámci implementácie odporúčacieho systému v tomto obchode. Na základe výsledkov tejto analýzy som navrhla dodatočné úpravy dát a spôsob extrahovania atribútov vhodných na vytvorenie vstupu pre odporúčací systém.

Ako odporúčací systém som si vybrala systém Recombee. V rámci neho som si reálne vytvorila databázu a implementovala som export dát s využitím Recombee API klienta a metód komunikujúcimi s koncovými bodmi API. Pomocou tohto exportu som vložila vyextrahované dáta do vytvorenej Recombee databázy a skúmala som nad nimi možnosti tohto systému.

Na základe informácii zistených počas študovania využívaných prístupov na vyhodnocovanie odporúčacích systémov som navrhla experimenty, výsledky ktorých mi slúžili na výber vhodného modelu nad danými dátami. V navrhnutých experimentoch som sa zamerala na rôzne odporúčacie modely obsiahnuté v rámci odporúčacieho systému Recombee a skúmala som ich možnosti prostredníctvom offline vyhodnocovania a zvoleným recall-coverage multiobjektívnym vyhodnocovaním. Výsledky týchto experimentov som názorne ilustrovala vygenerovanými odporúčaniami z vybraných modelov. Sústredila som sa aj na možnosti vyhodnocovaných modelov v situácii referujúcej na cold start problém.

Analýzou získaných výsledkov vyhodnocovania som v záverečnej časti tejto práce navrhla výber odporúčacieho modelu vhodného pre dané dáta.

9 Zoznam použitej literatúry

[1] F. Ricci, L. Rokach, B. Shapira, and P. B. Kantor, *Recommender systems handbook*. Springer, 2015.

[2] J. Bobadilla, F. Ortega, A. Hernando, and A. Gutiérrez, "Recommender systems survey," *Knowledge-based Syst.*, vol. 46, pp. 109–132, 2013.

[3] G. Adomavicius and A. Tuzhilin, "Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions," *IEEE Trans. Knowl. Data Eng.*, vol. 17, no. 6, pp. 734–749, 2005.

[4] J. Ben Schafer, D. Frankowski, J. Herlocker, and S. Sen, "Collaborative filtering recommender systems," in *The adaptive web*, Springer, 2007, pp. 291–324.

[5] J. Ben Schafer, J. Konstan, and J. Riedl, "Recommender systems in e-commerce," in *Proceedings of the 1st ACM conference on Electronic commerce*, 1999, pp. 158–166.

[6] M. Hristakeva, "The Components of a Recommender System," 2015. [Online]. Available: https://buildingrecommenders.wordpress.com/2015/11/10/the-components-of-a-recommender-system/. [Accessed: 18-Oct-2017].

[7] M. Hristakeva, "Don't Look Stupid," 2016. [Online]. Available: https://buildingrecommenders.wordpress.com/2016/02/01/dont-look-stupid/. [Accessed: 19-Oct-2017].

[8] D. Jannach, M. Zanker, A. Felfernig, and G. Friedrich, *Recommender Systems: An Introduction*, 1st ed. New York, NY, USA: Cambridge University Press, 2010.

[9] P. Kordik, "Recommender systems explained." [Online]. Available: https://medium.com/recombee-blog/recommender-systems-explained-d98e8221f468.

[10] M. Hristakeva, "Overview of Recommender Algorithms – Part 2," 2015. [Online]. Available: https://buildingrecommenders.wordpress.com/2015/11/18/overview-of-recommender-algorithms-part-2/. [Accessed: 12-Sep-2017].

[11] M. Hristakeva, "Overview of Recommender Algorithms – Part 3," 2015. [Online]. Available: https://buildingrecommenders.wordpress.com/2015/11/19/overview-of-recommender-algorithms-part-3/. [Accessed: 21-Sep-2017].

[12] R. Burke, "Hybrid recommender systems: Survey and experiments," *User Model. User-adapt. Interact.*, vol. 12, no. 4, pp. 331–370, 2002.

[13] M. Y. H. Al-Shamri, "User profiling approaches for demographic recommender systems," *Knowledge-Based Syst.*, vol. 100, no. Supplement C, pp. 175–187, 2016.

[14] M. J. Pazzani, "A framework for collaborative, content-based and demographic filtering," *Artif. Intell. Rev.*, vol. 13, no. 5–6, pp. 393–408, 1999.

[15] M. Vozalis and K. G. Margaritis, "Collaborative filtering enhanced by demographic correlation," in *AIAI symposium on professional practice in AI, of the 18th world computer congress*, 2004.

[16] M. A. Ghazanfar and A. Prugel-Bennett, "A scalable, accurate hybrid recommender system," in *Knowledge Discovery and Data Mining, 2010. WKDD'10. Third International Conference on*, 2010, pp. 94–98.

[17] M. Hristakeva, "Overview of Recommender Algorithms – Part 4," 2015. [Online]. Available: https://buildingrecommenders.wordpress.com/2015/11/20/overview-of-recommender-algorithms-part-4/. [Accessed: 23-Sep-2017].

[18] H. Gaspar, "The Cold Start Problem for Recommender Systems," 2015. [Online]. Available: http://www.yusp.com/blog/cold-start-problem-recommender-systems/. [Accessed: 15-Dec-2017].

[19] F. Baader, D. Calvanese, D. L. McGuiness, D. Nardi, and P. F. Patel-Schneider, "The Description Logic Handbook: Theory, Implementation and Applications," p. 624, 2003.

[20] C. W. ki Leung, S. C. fai Chan, and F. lai Chung, "An empirical study of a cross-level association rule mining approach to cold-start recommendations," *Knowledge-Based Syst.*, vol. 21, no. 7, pp. 515–529, 2008.

[21] H.-N. Kim, A.-T. Ji, I. Ha, and G.-S. Jo, "Collaborative filtering based on collaborative tagging for enhancing the quality of recommendation," *Electron. Commer. Res. Appl.*, vol. 9, no. 1, pp. 73–83, 2010.

[22] L. Martinez, L. G. Perez, and M. J. Barranco, "Incomplete preference relations to smooth out the cold-start in Collaborative Recommender Systems," in *Annual Conference of the North American Fuzzy Information Processing Society - NAFIPS*, 2009.

[23] W. Li-Tung, X. Yue, L. Yuefeng, and R. Nayak, "Exploiting item taxonomy for solving cold-start problem in recommendation making," in *Proceedings - International Conference on Tools with Artificial Intelligence, ICTAI*, 2008, vol. 2, pp. 113–120.

[24] J. Bobadilla, F. Ortega, A. Hernando, and J. Bernal, "A collaborative filtering approach to mitigate the new user cold start problem," *Knowledge-Based Syst.*, vol. 26, pp. 225–238, 2012.

[25] H. Sobhanam and a. K. Mariappan, "Addressing cold start problem in recommender systems using association rules and clustering technique," *2013 Int. Conf. Comput. Commun. Informatics*, pp. 1–5, 2013.

[26] S. Sahebi and W. W. Cohen, "Community-based recommendations: a solution to the cold start problem," *Work. Recomm. Syst. Soc. Web (RSWEB), held conjunction with ACM RecSys'11,* 2011.

[27] Z. K. Zhang, C. Liu, Y. C. Zhang, and T. Zhou, "Solving the cold-start problem in recommender systems with social tags," *EPL*, vol. 92, no. 2, 2010.

[28] "Krížový predaj (cross-selling)," 2016. [Online]. Available: https://managementmania.com/sk/krizovy-predaj-cross-selling. [Accessed: 15-Nov-2017].

[29] "Learn to upsell from Amazon- The power of Business analytics." [Online]. Available: https://www.linkedin.com/pulse/learn-upsell-from-amazon-power-business-analytics-vishal-rana/. [Accessed: 28-Nov-2017].

[30] K. Jack, "Recommender Systems in Netflix," 2015. [Online]. Available: https://buildingrecommenders.wordpress.com/2015/11/18/recommender-systems-in-netflix/. [Accessed: 18-Oct-2017].

[31] K. Jack, "Mendeley Suggest," 2015. [Online]. Available: https://buildingrecommenders.wordpress.com/2015/11/13/mendeley-suggest/. [Accessed: 18-Oct-2017].

[32] V. M. Moya-Oroyco, "Mendeley Institucional: Gestión de citas y referencias bibliográficas en Ciencias Sociales (2015)." [Online]. Available: https://www.slideshare.net/vicmoyoro/mendeley-institucional-gestin-de-citas-y-referencias-bibliogrficas-en-ciencias-sociales-2015. [Accessed: 29-Nov-2017].

[33] "Recommendation engine," 2017. [Online]. Available: http://www.fact-finder.com/products-and-services/recommendation-engine.html. [Accessed: 19-Sep-2017].

[34] "econda Cross Sell - Recommendation solution und engine," 2017. [Online]. Available: https://www.econda.de/en/solutions/personalization/cross-sell/. [Accessed: 20-Sep-2017].

[35] "Co je SaaS?" [Online]. Available: https://azure.microsoft.com/cs-

cz/overview/what-is-saas/. [Accessed: 03-Dec-2017].

[36] Y. GmbH, "YOOCHOOSE Personalization Solution." [Online]. Available: https://marketplace.magento.com/yoochoose-magento2-tracking.html. [Accessed: 03-Dec-2017].

[37] D. McGinnis, "Machine Learning Solutions: Recommender System Design," 2017. [Online]. Available: http://blogs.avalonconsult.com/blog/big-data/machine-learning-solutions-recommender-system-design-2/. [Accessed: 06-Nov-2017].

[38] "Evaluations," 2015. [Online]. Available: https://buildingrecommenders.wordpress.com/2015/11/12/evaluations/. [Accessed: 12-Dec-2017].

[39] A. Gunawardana and G. Shani, "A survey of accuracy evaluation metrics of recommendation tasks," *J. Mach. Learn. Res.*, vol. 10, no. Dec, pp. 2935–2962, 2009.

[40] P. Kordík and T. Řehořek, "Recall-Coverage Multi-Objective Evaluation in Recommender Systems."

[41] J. L. Herlocker, J. A. Konstan, L. G. Terveen, and J. T. Riedl, "Evaluating collaborative filtering recommender systems," *ACM Trans. Inf. Syst.*, vol. 22, no. 1, pp. 5–53, 2004.

[42] J. Dvořák, "Integrace rekomendačního systému do portálu SSP," České vysoké učenie technické v Prahe, 2016.

[43] T. Pang-Ning, M. Steinbach, and V. Kumar, *Introduction to data mining*. 2006.

[44] P. Kordík, "Recommender systems explained," 2016. [Online]. Available: https://medium.com/recombee-blog/recommender-systems-explained-d98e8221f468. [Accessed: 21-Dec-2017].

Zoznam príloh

Príloha A Grafy výsledkov vyhodnocovania odporúčacích modelov

Príloha B Ukážka odporúčaní pre vybraných používateľov

Príloha C Obsah priloženého CD

Príloha A Grafy výsledkov vyhodnocovania odporúčacích modelov

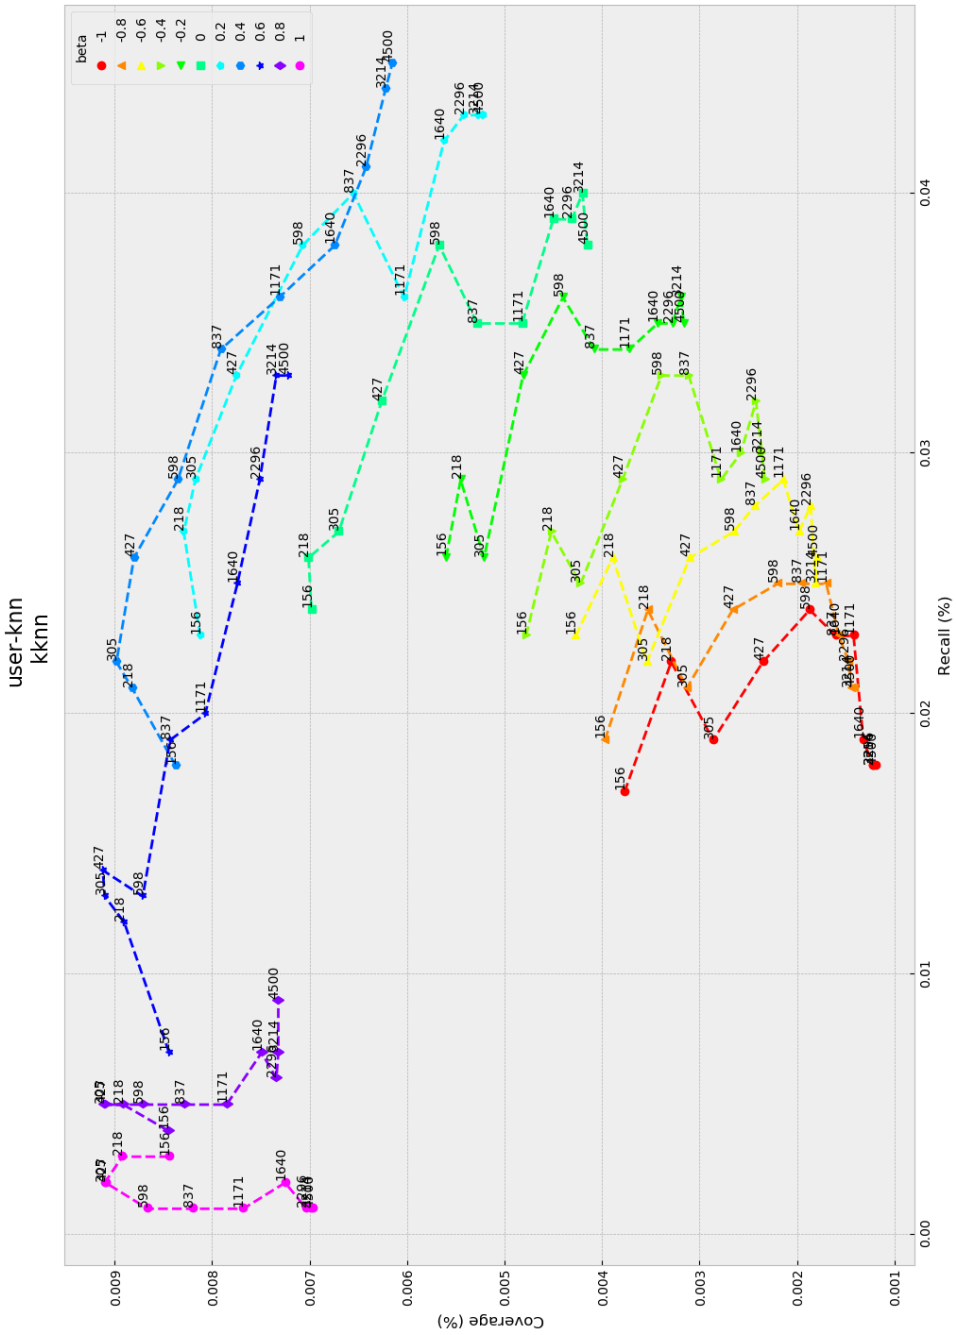

Obrázok A.1 Graf získaných hodnôt recall a coverage počas vyhodnocovania modelu UserkNN nad dátami s objektmi úrovne *product colot variant*

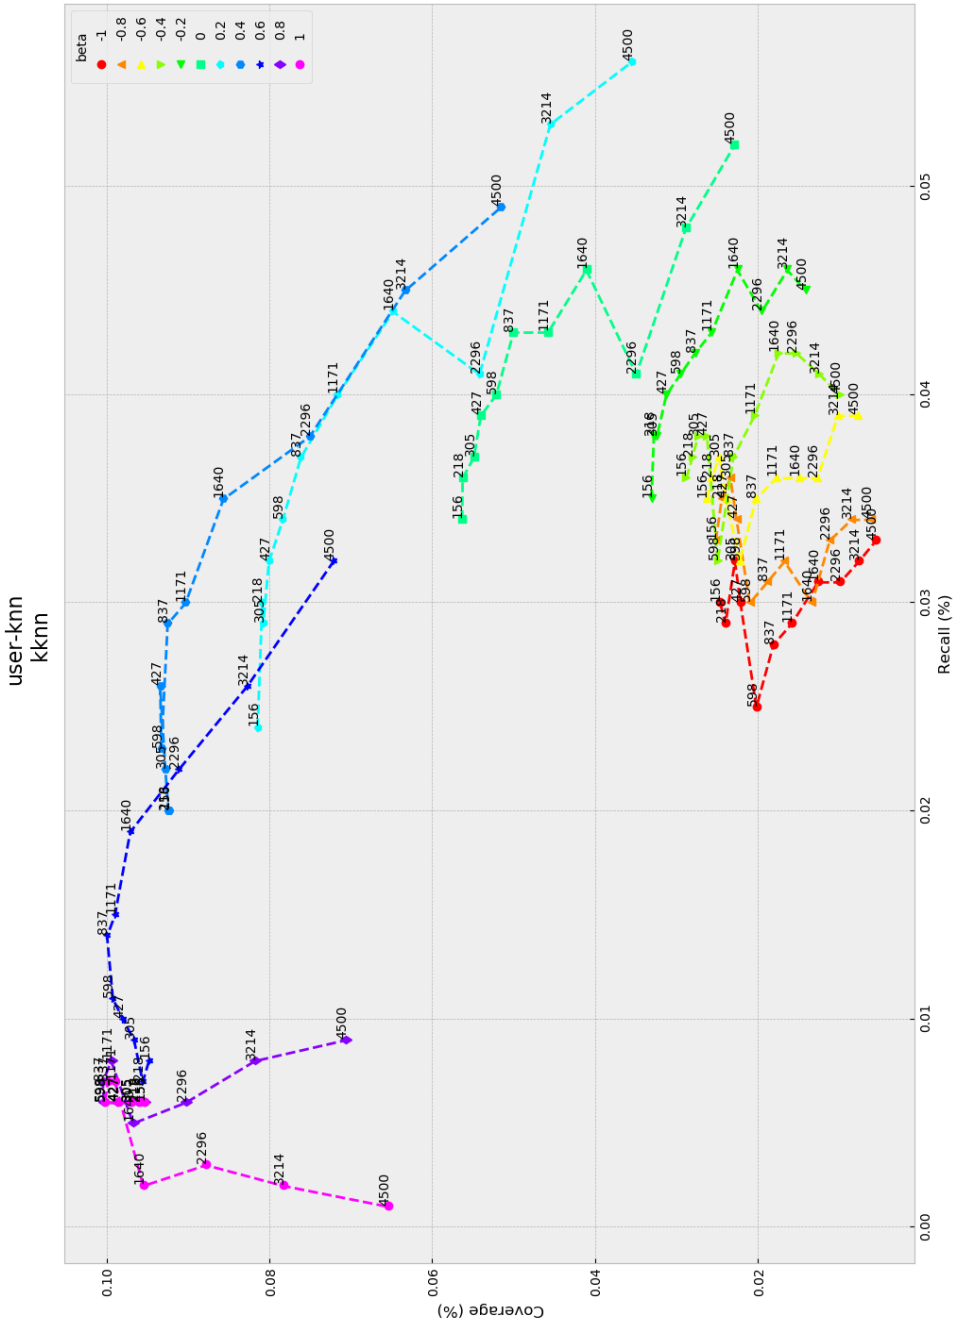

Obrázok A.2 Graf získaných hodnôt recall a coverage počas vyhodnocovania modelu UserkNN nad dátami s objektmi úrovne *product*

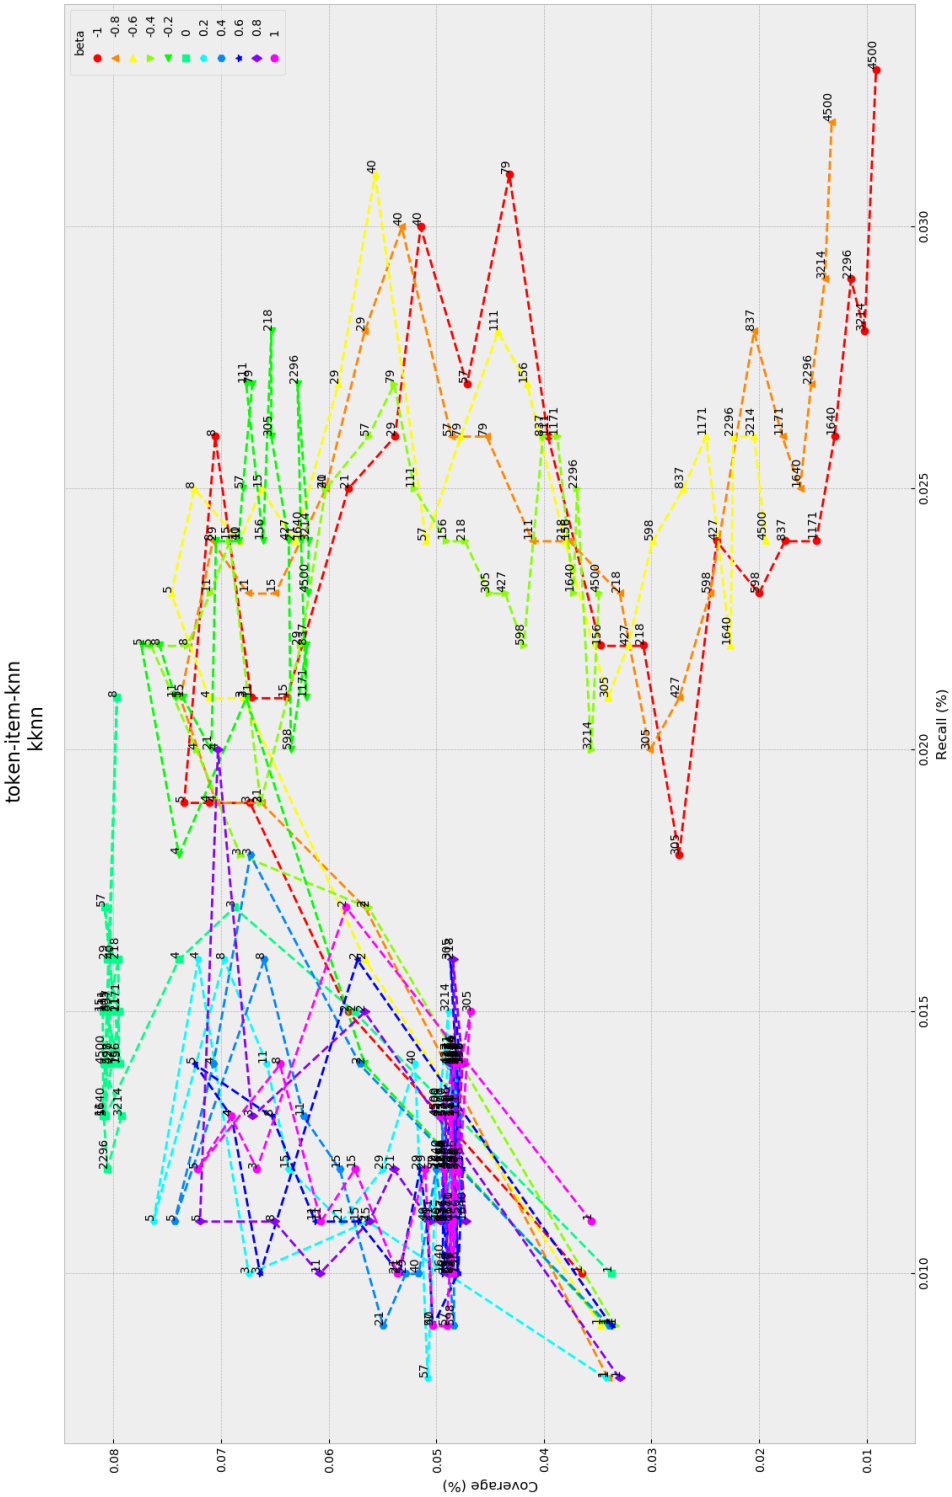

Obrázok A.3 Graf získaných hodnôt recall a coverage počas vyhodnocovania modelu Token Item kNN s kombináciou atribútov objektov značka, kategória, pohlavie, farba, materiál, krátky popis, dlhý popis

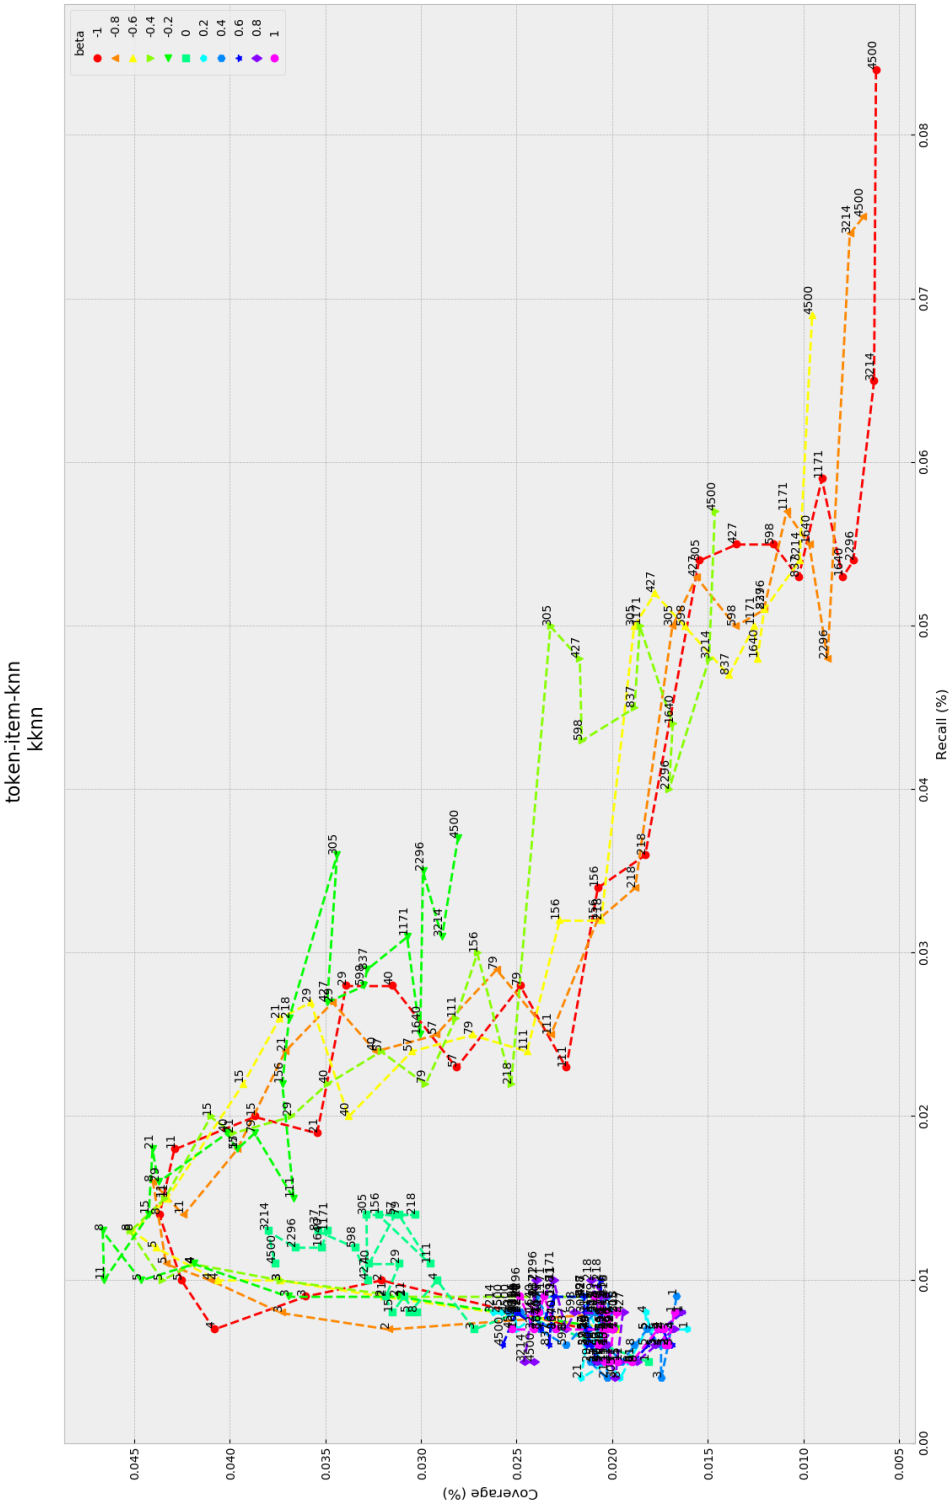

Obrázok A.4 Graf získaných hodnôt recall a coverage počas vyhodnocovania modelu Token Item kNN s kombináciou atribútov objektov značka, kategória, pohlavie

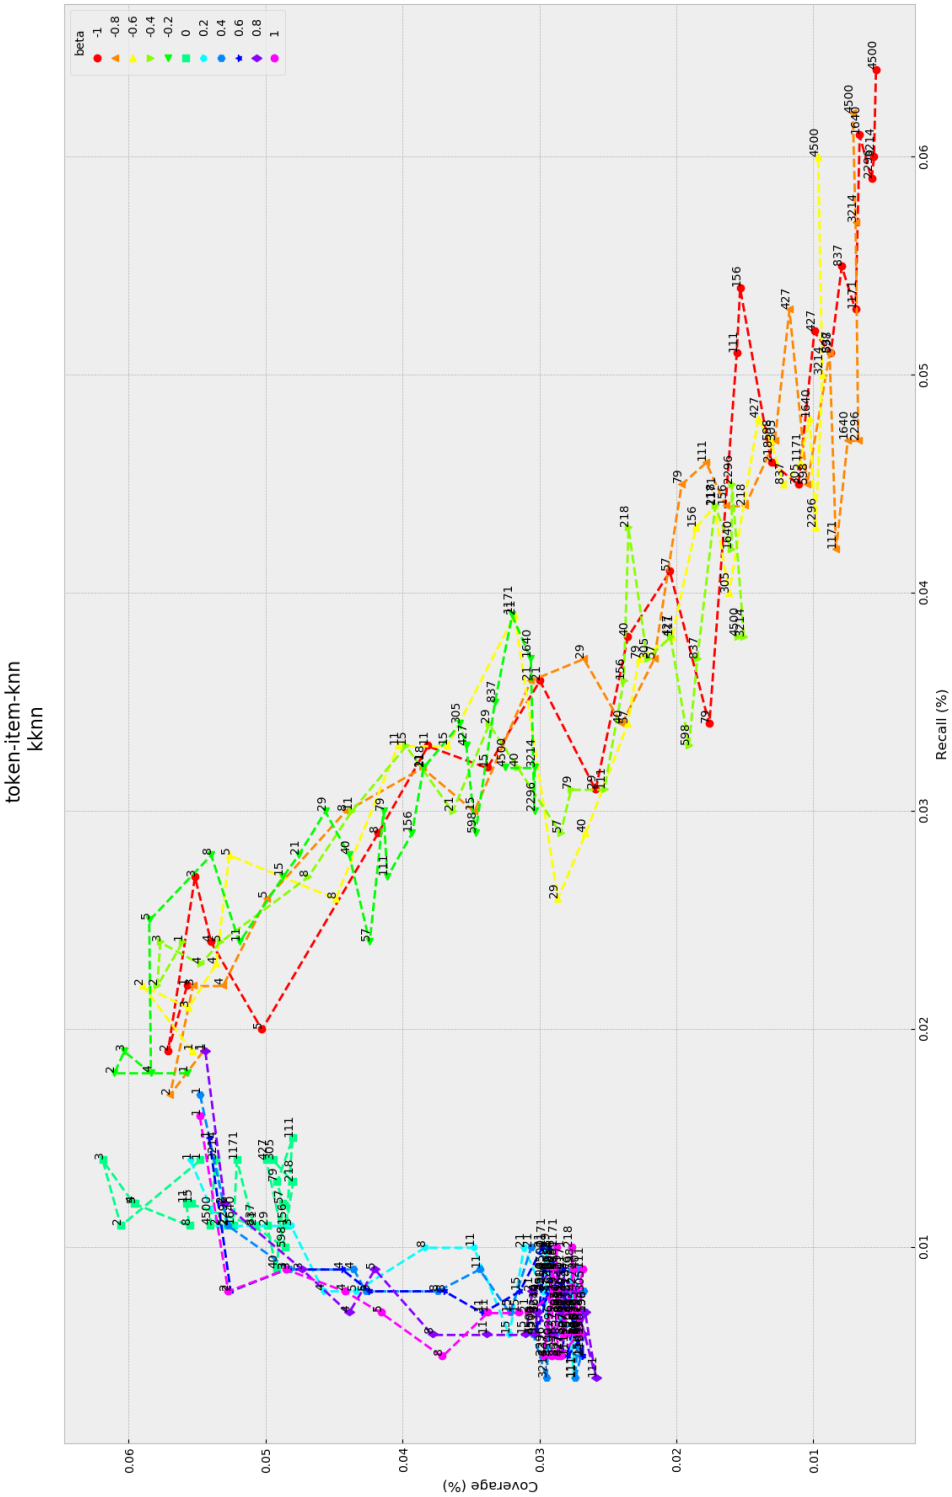

Obrázok A.5 G Graf získaných hodnôt recall a coverage počas vyhodnocovania modelu Token Item kNN s kombináciou atribútov objektov značka, kategória, pohlavie, krátky popis

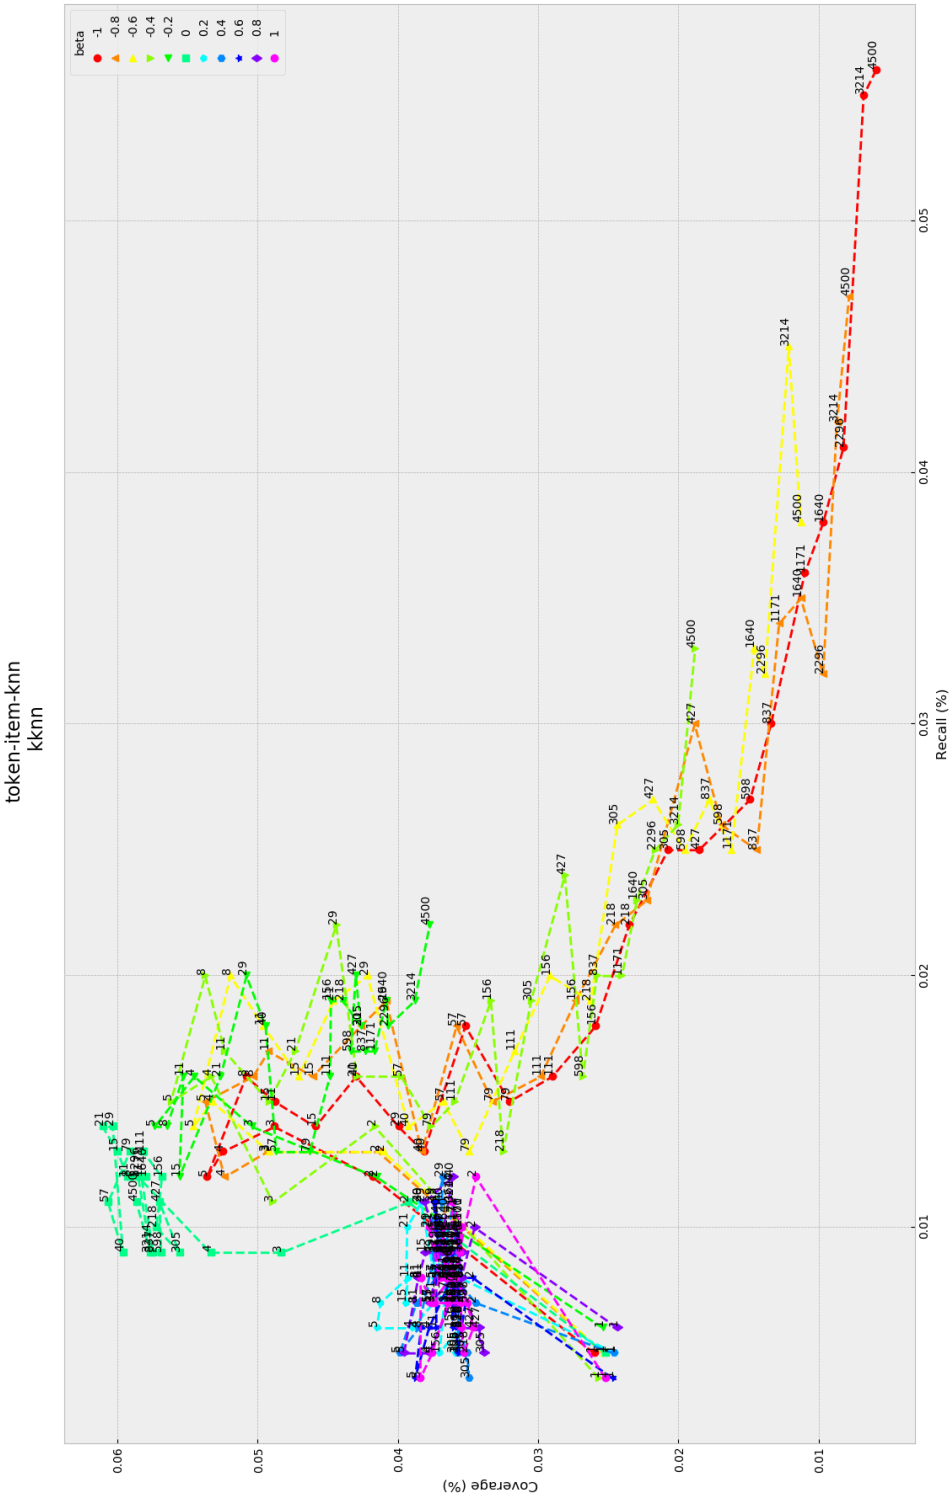

Obrázok A.6 Graf získaných hodnôt recall a coverage počas vyhodnocovania modelu Token Item kNN s kombináciou atribútov objektov značka, kategória, pohlavie, farba

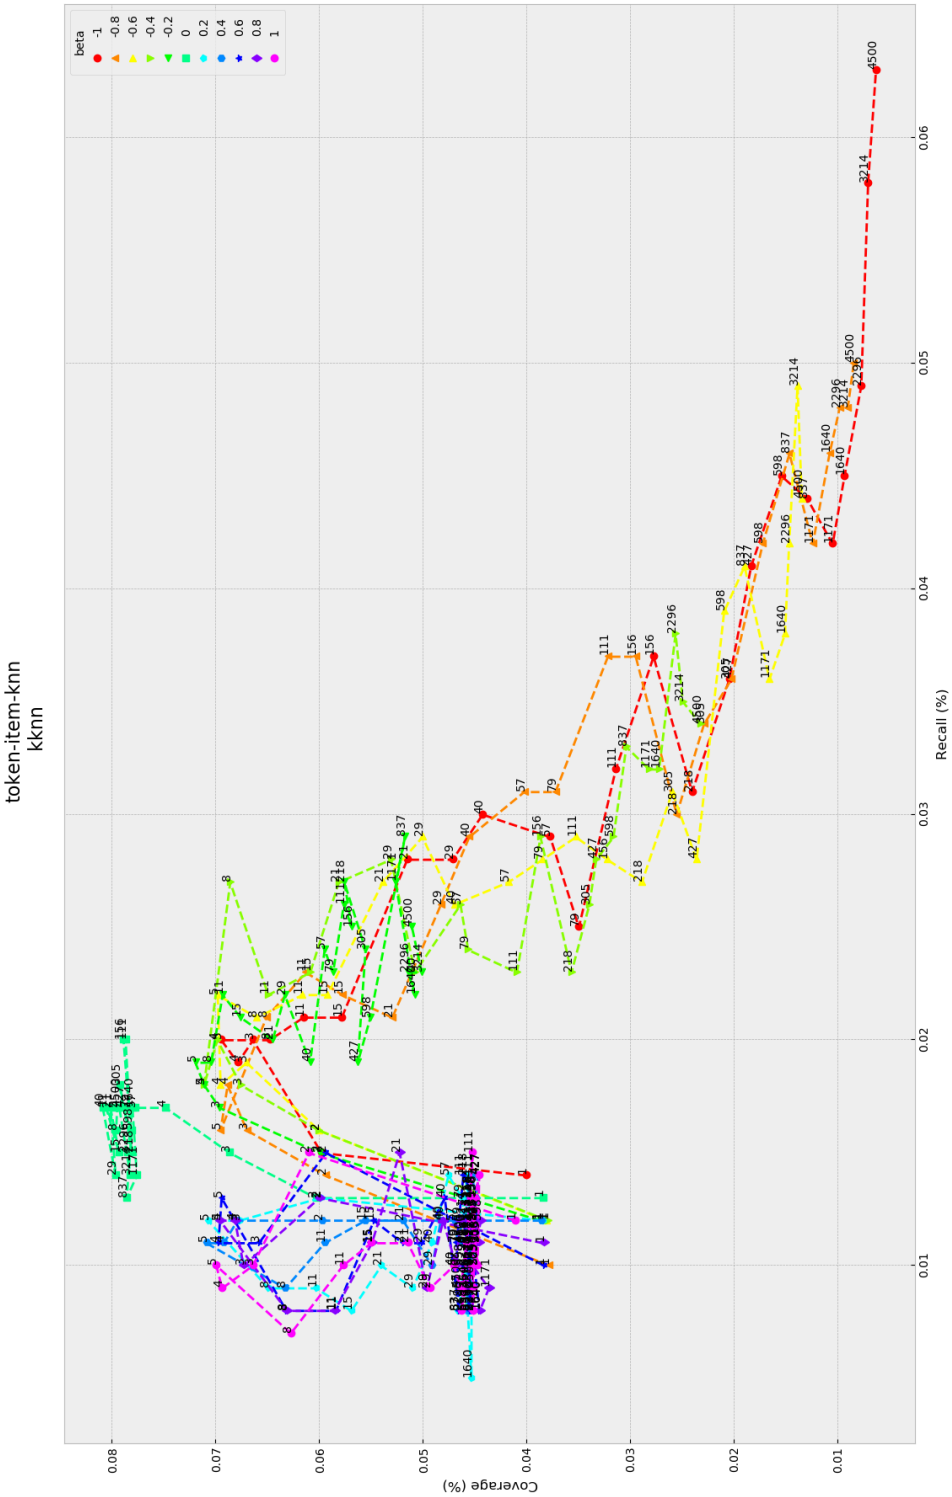

Obrázok A.7 Graf získaných hodnôt recall a coverage počas vyhodnocovania modelu Token Item kNN s kombináciou atribútov objektov značka, kategória, pohlavie, farba, krátky popis

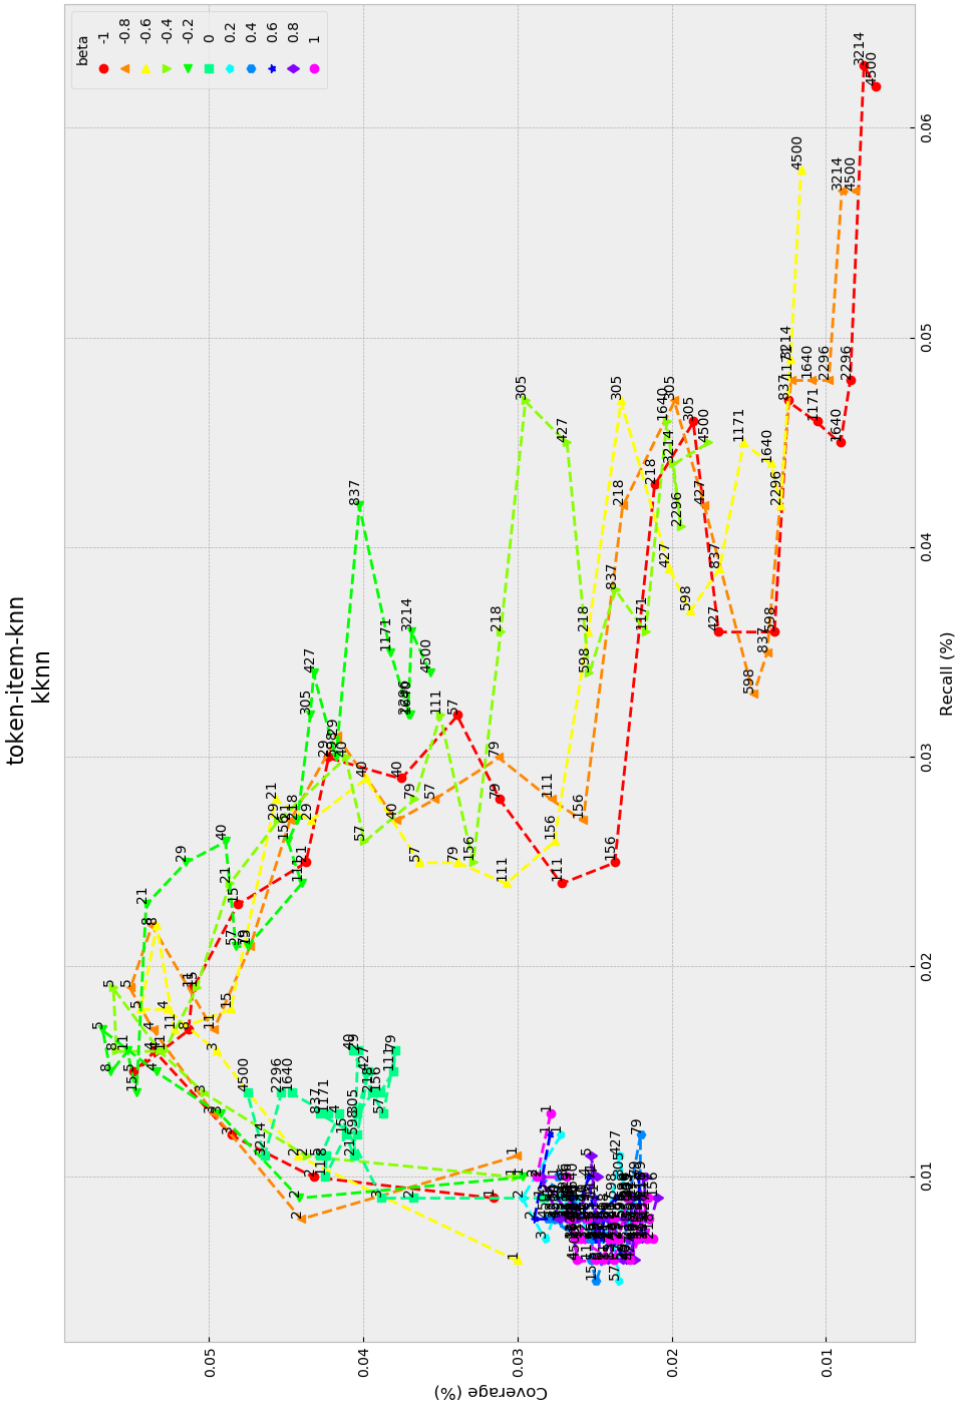

Obrázok A.8 Graf získaných hodnôt recall a coverage počas vyhodnocovania modelu Token Item kNN s kombináciou atribútov objektov značka, kategória, pohlavie, materiál

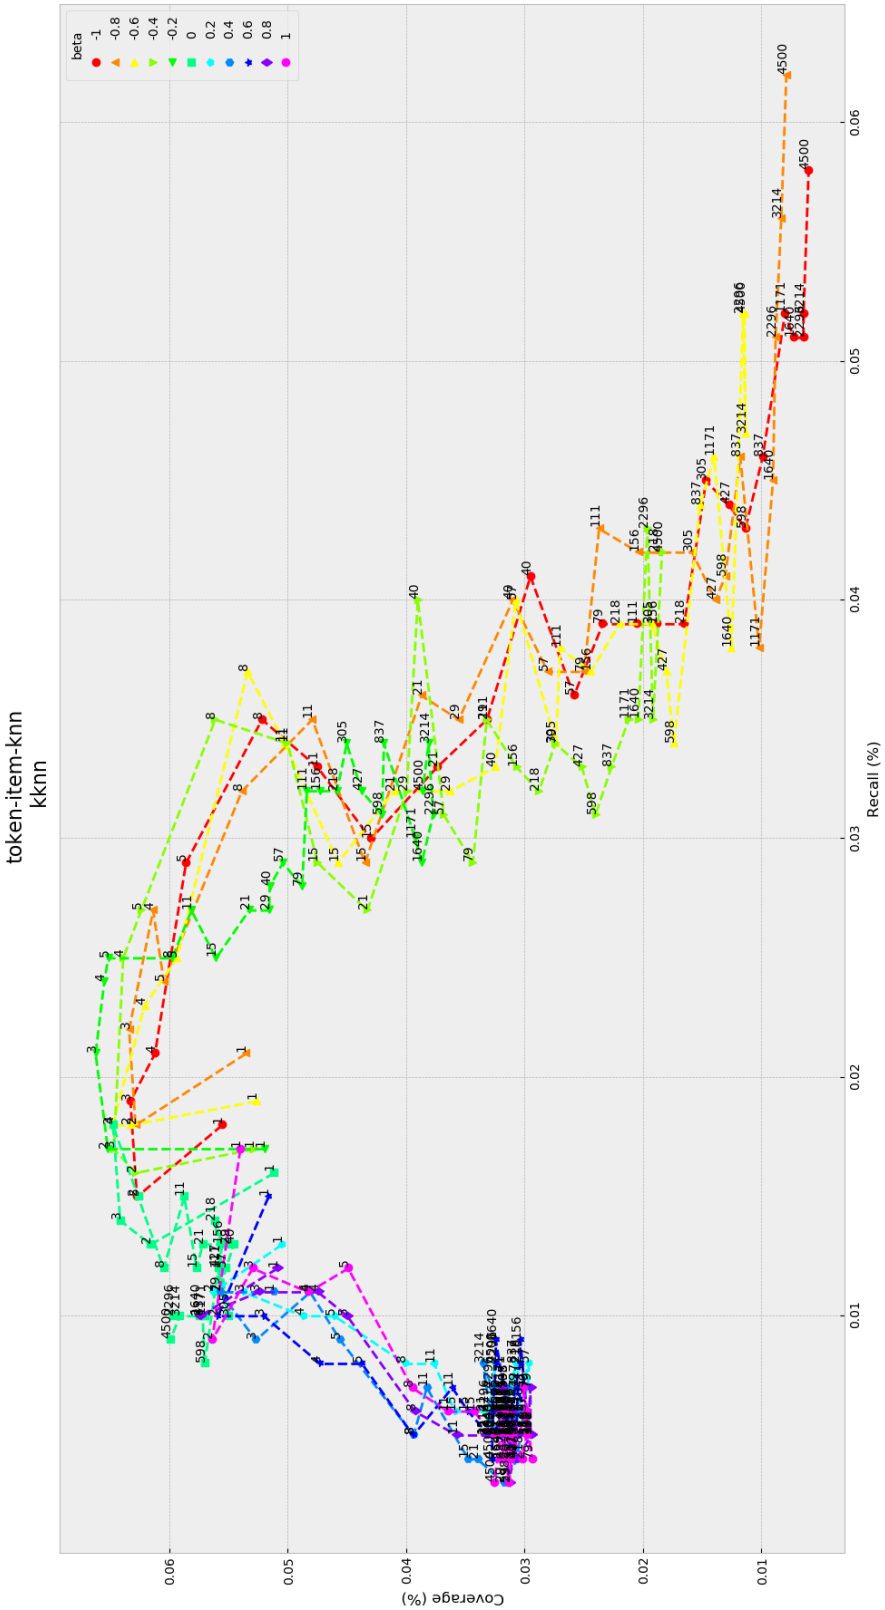

Obrázok A.9 Graf získaných hodnôt recall a coverage počas vyhodnocovania modelu Token Item kNN s kombináciou atribútov objektov značka, kategória, pohlavie, materiál, krátky popis

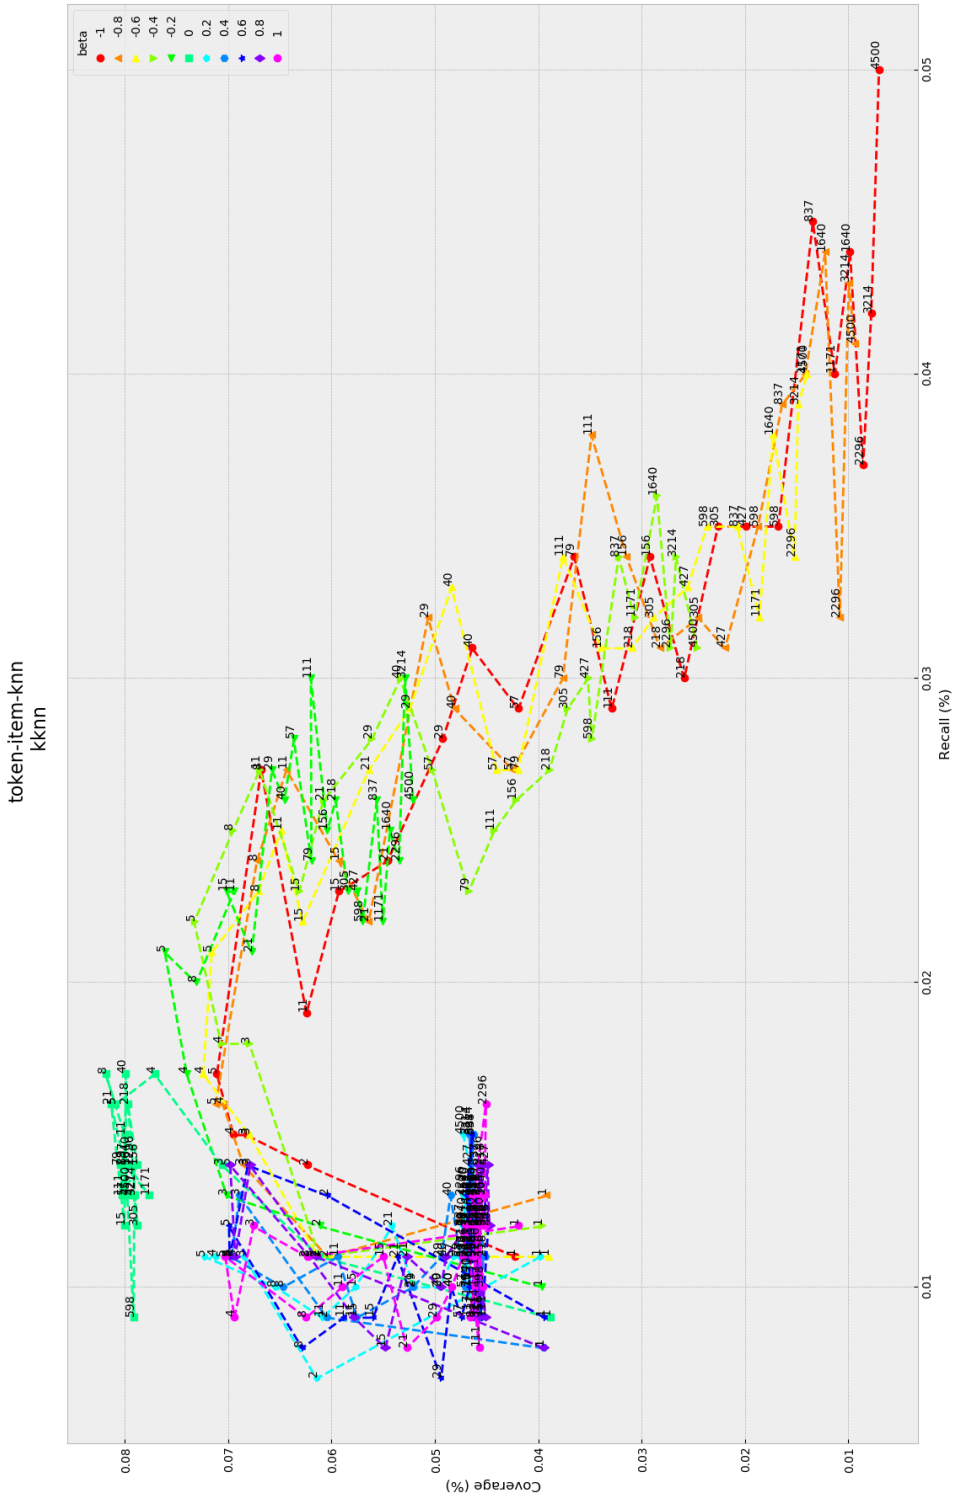

Obrázok A.10 Graf získaných hodnôt recall a coverage počas vyhodnocovania modelu Token Item kNN s kombináciou atribútov objektov značka, kategória, pohlavie, farba, materiál, krátky popis

Príloha B Ukážka vygenerovaných odporúčaní pre vybraných používateľov

B.1 UserkNN model s parametrami kknn =1171, β = 0.2

Tabuľka B.1 Popis odporúčaní vygenerovaných UserkNN modelom pre používateľa 699251

Testovaný používateľ 699251, počet zakúpených objektov: 2		
Trénovacia časť vzorky:		
Id	Obrázok	Popis
40180		Značka: adidas performance Pohlavie: M Kategória: basketball shoes
Vygenerované odporúčania:		
Id	Obrázok	Popis
41805	Obrázok nie je dostupný	Značka: adidas performance Pohlavie: M Kategória: basketball shoes
41809		Značka: adidas performance Pohlavie: M Kategória: basketball shoes

42382		Značka: nike Pohlavie: M Kategória: basketball shoes
38703		Značka: adidas performance Pohlavie: M Kategória: basketball shoes
54803		Značka: nike Pohlavie: M Kategória: hoodies

Tabuľka B.2 Popis odporúčaní vygenerovaných UserkNN modelom pre používateľa 497661

Testovaný používateľ 497661, počet zakúpených objektov: 3		
Trénovacia časť vzorky:		
Id	Obrázok	Popis
24687		Značka: k swiss Pohlavie: M Kategória: sneakers low

27562		Značka: lrg Pohlavie: M Kategória: t-shirts
Vygenerované odporúčania:		
Id	Obrázok	Popis
2921		Značka: k1x Pohlavie: M Kategória: basketball shoes; sneakers high; sneakers low
24686		Značka: k swiss Pohlavie: M Kategória: sneakers high
24689		Značka: k swiss Pohlavie: M Kategória: sneakers low
24688		Značka: k swiss Pohlavie: M Kategória: sneakers low

5947		Značka: k1x Pohlavie: M Kategória: sneakers low

Tabuľka B.3 Popis odporúčaní vygenerovaných UserkNN modelom pre používateľa 769353

Testovaný používateľ 769353, počet zakúpených objektov: 4		
Trénovacia časť vzorky:		
Id	Obrázok	Popis
2795		Značka: k1x wmns Pohlavie: F Kategória: t-shirts
36718		Značka: k1x wmns Pohlavie: F Kategória: shorts and bermudas
54896		Značka: nike Pohlavie: M Kategória: basketball shoes

Vygenerované odporúčania:		
Id	Obrázok	Popis
26153	Obrázok nie je dostupný	Značka: k1x wmns Pohlavie: F Kategória: sleeveless shirts; tank tops
32166		Značka: k1x wmns Pohlavie: F Kategória: sleeveless shirts; tank tops
6003		Značka: k1x wmns Pohlavie: F Kategória: shorts and bermudas
36730		Značka: k1x wmns Pohlavie: F Kategória: sleeveless shirts; tank tops
36686		Značka: k1x wmns Pohlavie: F Kategória: sleeveless shirts; tank tops

B.2 Ranking Item kNN model s parametrami kknn = 598, β = 0

Tabuľka B.4 Popis odporúčaní vygenerovaných Ranking Item kNN modelom pre používateľa 699251

Testovaný používateľ 699251, počet zakúpených objektov: 2		
Trénovacia časť vzorky:		
Id	Obrázok	Popis
40180		Značka: adidas performance Pohlavie: M Kategória: basketball shoes
Vygenerované odporúčania:		
Id	Obrázok	Popis
33884		Značka: nike Pohlavie: M Kategória: tank tops
41805	Obrázok nie je dostupný	Značka: adidas performance Pohlavie: M Kategória: basketball shoes
41809		Značka: adidas performance Pohlavie: M Kategória: basketball shoes

40071		Značka: under armour Pohlavie: M Kategória: basketball shoes
38703		Značka: adidas performance Pohlavie: M Kategória: basketball shoes

Tabuľka B.5 Popis odporúčaní vygenerovaných Ranking Item kNN modelom pre používateľa 497661

Testovaný používateľ 497661, počet zakúpených objektov: 3		
Trénovacia časť vzorky:		
Id	Obrázok	Popis
24687		Značka: k swiss Pohlavie: M Kategória: sneakers low
27562		Značka: lrg Pohlavie: M Kategória: t-shirts

Vygenerované odporúčania:		
Id	Obrázok	Popis
24388		Značka: lrg Pohlavie: M Kategória: t-shirts
22542		Značka: osiris Pohlavie: M Kategória: t-shirts
3384		Značka: lrg Pohlavie: M Kategória: t-shirts
24689		Značka: k swiss Pohlavie: M Kategória: sneakers low
24688		Značka: k swiss Pohlavie: M Kategória: sneakers low

Tabuľka B.6 Popis odporúčaní vygenerovaných Ranking Item kNN modelom pre používateľa 769353

Testovaný používateľ 769353, počet zakúpených objektov: 4		
Trénovacia časť vzorky:		
Id	Obrázok	Popis
2795		Značka: k1x wmns Pohlavie: F Kategória: t-shirts
36718		Značka: k1x wmns Pohlavie: F Kategória: shorts and bermudas
54896		Značka: nike Pohlavie: M Kategória: basketball shoes
Vygenerované odporúčania:		
Id	Obrázok	Popis
26153	Obrázok nie je dostupný	Značka: k1x wmns Pohlavie: F Kategória: sleeveless shirts; tank tops

33718		Značka: k1x wmns Pohlavie: F Kategória: training; training pants
36730		Značka: k1x wmns Pohlavie: F Kategória: sleeveless shirts; tank tops
36686		Značka: k1x wmns Pohlavie: F Kategória: sleeveless shirts; tank tops
36724		Značka: k1x wmns Pohlavie: F Kategória: shorts and bermudas

B.3 Token Item kNN model s parametrami kknn = 8, β = -0.6 nad dátami objektov s atribútmi značka, kategória, pohlavie, materiál, krátky popis

Tabuľka B.7 Popis odporúčaní vygenerovaných Token Item kNN modelom pre používateľa 699251

Testovaný používateľ 699251, počet zakúpených objektov: 2		
Trénovacia časť vzorky:		
Id	Obrázok	Popis
40180		Značka: adidas performance Pohlavie: M Kategória: basketball shoes
Vygenerované odporúčania:		
Id	Obrázok	Popis
40178		Značka: adidas Pohlavie: M Kategória: basketball shoes
41809		Značka: adidas performance Pohlavie: M Kategória: basketball shoes

55477		Značka: adidas performance Pohlavie: M Kategória: basketball shoes
41811		Značka: adidas performance Pohlavie: M Kategória: basketball shoes
41812		Značka: adidas performance Pohlavie: M Kategória: basketball shoes

Tabuľka B.8 Popis odporúčaní vygenerovaných Token Item kNN modelom pre používateľa 497661

Testovaný používateľ 497661, počet zakúpených objektov: 3		
Trénovacia časť vzorky:		
Id	Obrázok	Popis
24687		Značka: k swiss Pohlavie: M Kategória: sneakers low

27562		Značka: lrg Pohlavie: M Kategória: t-shirts
Vygenerované odporúčania:		
Id	Obrázok	Popis
30497		Značka: k swiss Pohlavie: M Kategória: sneakers low
26672		Značka: k swiss Pohlavie: F Kategória: sneakers low
26671		Značka: k swiss Pohlavie: K Kategória: sneakers low
3322		Značka: k swiss Pohlavie: M Kategória: sneakers low

24688		Značka: k swiss Pohlavie: M Kategória: sneakers low

Tabuľka B.9 Popis odporúčaní vygenerovaných Token Item kNN modelom pre používateľa 769353

Testovaný používateľ 769353, počet zakúpených objektov: 4		
Trénovacia časť vzorky:		
Id	Obrázok	Popis
2795		Značka: k1x wmns Pohlavie: F Kategória: t-shirts
36718		Značka: k1x wmns Pohlavie: F Kategória: shorts and bermudas
54896		Značka: nike Pohlavie: M Kategória: basketball shoes

Vygenerované odporúčania:		
Id	Obrázok	Popis
44144		Značka: nike Pohlavie: M Kategória: basketball shoes
41398		Značka: nike Pohlavie: M Kategória: basketball shoes
54895		Značka: nike Pohlavie: M Kategória: basketball shoes
40666		Značka: nike Pohlavie: M Kategória: basketball shoes
42382		Značka: nike Pohlavie: M Kategória: basketball shoes

Príloha C Obsah priloženého CD

Z hľadiska ochrany údajov a zaviazaní sa o mlčanlivosti nie je možné v rámci tejto práce poskytnúť akékoľvek dáta ponúknuté e-shopom Kickz. Takisto nie je možné priložiť zdrojové kódy, ktoré by nejakým spôsobom odhaľovali štruktúru produkčnej databázy tohto e-shopu.

Štruktúra priloženého CD:

1. *readme.txt* – popisuje obsah CD
2. */exporter/* – export dát a manipulácia s Recombee DB
    a. */exporter/src/* – zdrojové kódy
    b. */exporter/exportData/* – priečinok, z ktorého sa načítavajú dáta určené na export
    c. */exporter/config/* – konfiguračný súbor s hodnotami userId a token Recombee DB
    d. */exporter/query.txt* – príkazy, ktoré boli používané na prácu s dátami v lokálnej DB
    e. */exporter/readme.txt* – inštrukcie k exportu dát
    f. */exporter/pom.xml*
3. */text/* – text diplomovej práce v zdrojovom formáte (docx) a výslednom vytlačenom formáte (pdf)