

Gyöngyvér KOVÁCS

Faculty of Economics and Business Administration, Babeş-Bolyai University of Cluj-Napoca

Mihai-Constantin AVORNICULUI

Faculty of Economics and Business Administration, Babeş-Bolyai University of Cluj-Napoca

Botond BENEDEK

The CRM Expert, Cluj-Napoca

RECOMMENDER SYSTEMS IN E-COMMERCE APPLICATIONS

Theoretical Articles

Keywords

*Recommender system,
E-commerce,
Recommendation algorithm,
Marketing recommender system*

JEL Classification

M15

Abstract

One of the major problem with online shopping is finding the right product, because finding the right product presumes that we know its name, but in most cases it is not so. For this reason the users need help in the process of online searching/shopping. Recommender systems have become a popular technique and strategy for helping users to select desirable products or services. In the past few years the recommender systems have changed from novelties used by a few big e-commerce sites, to serious business tools that are reshaping the world of e-commerce. In this paper, we provide a brief overview of the classification of recommendation systems based on technology used to create recommendations, and inputs they need from the customers. Furthermore we analyze a few algorithms used by recommender systems and we will also present some marketing recommender systems and their comparative analysis.

INTRODUCERE

Una dintre problemele majore pentru cumpărătorii online este găsirea produsului căutat. În majoritatea cazurilor de magazine electronice clienții trebuie să navigheze printr-un catalog organizat ierarhic sau pot să folosească funcția de căutare din site. Aceste soluții presupun că clientul știe exact ce dorește să cumpere. În majoritatea cazurilor însă nu este așa, ei nu știu cu adevărat cum să caute și au nevoie de sprijin în procesul de cumpărare online.

Sistemele de recomandare sunt o alternativă utilă la căutarea unui produs prin motorul de căutare inclus în site sau navigarea prin catalog și ajută utilizatorii să descopere produse pe care poate nu le-ar fi găsit singuri.

Sistemele de recomandare se transformă din curiozități întâlnite pe câteva site-uri de comerț electronic în instrumente de afaceri serioase. Cele mai multe mari site-uri de comerț electronic folosesc aceste sisteme cu scopul de a ajuta clienții să găsească produsele pe care aceștia doresc să le cumpere, sporind astfel gradul de satisfacție a clientului și măbind veniturile din vânzări a site-ului de comerț electronic.

Un sistem de recomandare studiază fiecare client și recomandă produse care prezintă interes pentru clientul respectiv din gama largă de produse disponibile. Clienții vor fi încurajați de abordarea individualizată să crească volumul și frecvența achizițiilor.

În acest articol ropunem o clasificare a sistemelor de recomandare, bazată pe tehnologiile utilizate pentru crearea recomandărilor și intrările de care au nevoie din partea clienților. Analizăm algoritmi folosiți de sistemele de recomandare și vom prezenta câteva sisteme de recomandare și analiza lor comparativă.

SISTEME DE RECOMANDARE – CONCEPTE GENERALE

Sistemele de recomandare sunt aplicații care furnizează sfaturi utilizatorilor despre produse sau servicii disponibile pe site, de care ei pot fi interesați. Ideea generală este prezentată în figura 1.

Trecerea la comerțul electronic a permis companiilor să furnizeze clienților mai multe opțiuni (Gubán & Kása, 2013jj). Dar prin acesta afacerile sporesc volumul informației care trebuie prelucrată de către clienți înainte ca ei să poată selecta articolele care să corespundă nevoilor lor.

O soluție la problema supraîncărcării de informație este folosirea sistemelor de recomandare, care se folosesc în site-urile E-commerce pentru a sugera produse consumatorilor.

Produsele recomandate pot fi cele mai bine vândute produse din site, sau se pot determina

pe baza informațiilor demografice ale clienților, sau pornind de la o analiză a comportamentului de cumpărare din trecut a clientului. Aceste tehnici constituie o posibilitate de personalizare pe un site, deoarece ajută site-ul să se adapteze la fiecare client.

În consecință, sistemele de recomandare automatizează personalizarea pe Web, dând posibilitatea de personalizare individuală pentru fiecare client. Sistemele de recomandare creează valoare atât pentru site-urile E-commerce cât și pentru clienții lor (Kovács, 2007).

Sistemele de recomandare **sporesc vânzările** E-commerce în trei moduri (Schafer și alții 2001):

1. **Transformând vizitatorii în cumpărători:** Utilizatorii Internet adesea examinează site-uri fără să cumpere vreodată ceva. Sistemele de recomandare pot ajuta consumatorii să găsească produse pe care ei vor dori să le cumpere.
2. **Prin cross-sell (vânzări încrucișate):** Sistemele de recomandare pot îmbunătăți aceste tipuri de vânzări prin sugerarea produselor adiționale pentru cumpărare. De exemplu în momentul finalizării unei comenzi, se pot recomanda produse adiționale celor care se află în coșul cumpărătorului. Astfel valoarea medie a comenzilor va crește.
3. **Loialitate:** Într-o lume virtuală, unde concurenții site-ului sunt numai la un clic, a câștiga loialitatea clienților este o strategie de afacere necesară. Sistemele de recomandare îmbunătățesc loialitatea creând o relație cu valoare adăugată între site și client. Site-urile investesc în studierea utilizatorilor lor, folosind sistemele de recomandare prezintă interfețe personalizate, care se potrivesc nevoilor fiecărui client în parte. Clienții recompensează aceste site-uri revenind la cele care corespund cel mai bine gusturilor lor. Cu cât un client folosește mai mult un anumit sistem de recomandare – învățându-l ce dorește – cu atât va deveni mai loial site-ului. Chiar dacă un alt site va oferi același tip de sistem de recomandare, clientul va trebui să investească efort și timp pentru ca acesta să-i ofere aceleași posibilități.
4. În cele din urmă, creând **relații între clienți** poate de asemenea să sporească loialitatea. Clienții se vor întoarce la site-ul care le recomandă oameni cu care ei vor interacționa cu plăcere.

TIPURI DE SISTEME DE RECOMANDARE

1. **Sisteme ne-personalizate** Sistemele ne-personalizate recomandă produse independent de cine este clientul, așa că fiecare client primește aceleași recomandări. Aceste sisteme sunt automate, deoarece ei nu necesită efort

din partea clientului pentru a genera recomandarea.

2. Recomandări bazate pe proprietățile produsului
3. Corelare articol-cu-articol. Sistemele de recomandare bazate pe acest tip de corelare nu necesită cunoașterea unor informații prealabile despre client.
4. Corelare persoană-cu-persoană. Recomandă produse unui client bazat pe corelarea între acel client și alți clienți care au cumpărat produse de pe site-ul e-commerce. Această metodă este numită de obicei filtrare colaborativă ("collaborative filtering"). Este în mod curent inclus în sistemele de comerț electronic, folosit de exemplu și de Amazon.

INPUTURI DE LA UTILIZATORI

Fiecare din tehnologiile de recomandare anterioare necesită niște forme de intrare pe care să se bazeze recomandările. De obicei aceste intrări sunt furnizate de către clienți, în mod implicit sau explicit.

Sistemele existente utilizează una sau mai multe din următoarele tipuri de intrări:

1. **Informații despre produsele cumpărate.** Amazon și emag fac recomandări bazate în întregime pe modelele de cumpărare a multiplilor clienți, având ca punct de pornire produsele pe care un client le-a cumpărat. În principiu, eficiența acestui model poate fi sporit luând în considerare și ce cantitate a cumpărat clientul dintr-un anumit produs.
2. **Aprecieri:** Ce spune clientul referitor la un produs, de obicei pe o scară de 1-5 sau 1-7. Scara poate fi compusă și din valori textuale, numai să fie complet ordonat. Sisteme ca de exemplu Amazon Customer Reviews, Ebay's Feedback și Levi's Style Finder utilizează intrări de acest tip.
3. **Text:** Comentariile scrise de către clienți cu intenția ca alți utilizatori să le citească. Aceste comentarii de obicei nu sunt interpretate de către calculator. Este inclus la momentul actual în multe site-uri. Este folosit și de către Amazon.com (modulul Customer Comments).
4. **Alegerea editorului:** Selectări dintr-o categorie făcute de editori umani, de obicei angajați de site-ul E-commerce. Este posibilă și folosirea unor editori independenți. Alegerea editorului este folosită de exemplu în Moviefinder.com (Match Maker).

ALGORITMI DE RECOMANDARE

Există mai multe abordări bine cunoscute pentru a construi sisteme de recomandare:

- Case-based/Stereotype based
- Feature-based/Content-based
- Collaborative Filtering

Cele mai multe sisteme de recomandare folosesc filtrarea colaborativă sau metodele Content-based pentru a alege articole noi care ar putea interesa utilizatorul. În timp ce ambele metode au avantajele lor proprii, în mod individual ele eșuează să furnizeze recomandări bune în multe situații. Încorporând componente de la ambele metode, un sistem de recomandare hibrid poate să înfrângă aceste o lipsuri.

ALGORITMI COLLABORATIVE FILTERING

În această secțiune prezentăm o scurtă analiză a sistemelor de recomandare bazate pe algoritmi de filtrare colaborativă. Scopul unui algoritm de filtrare colaborativă este să sugereze articole noi sau să prezică utilitatea unui anumit articol pentru un anumit utilizator bazându-se pe preferințele exprimate anterior și părerile altor utilizatori cu gusturi similare.

În cazul tipic, există o listă de m utilizatori, $U = \{u_1, u_2, \dots, u_m\}$ și o listă de n articole $I = \{i_1, i_2, \dots, i_n\}$. Fiecărui utilizator u_i îi corespunde o listă de articole I_{ui} , pentru care utilizatorul a manifestat interes sau și-a exprimat părerea. Aceste opinii pot fi exprimate explicit printr-un scor de evaluare (*rating score*), în general dintr-o scară numerică, sau pot fi obținute implicit din înregistrările legate de procesul de cumpărare. Specificăm faptul că $I_{ui} \subseteq I$ și este posibil ca I_{ui} să fie mulțime vidă. Distingem un utilizator $u_a \in U$, numit **utilizatorul activ** pentru care algoritmul de filtrare colaborativă are sarcina să determine o potrivire care poate lua două forme:

- **predicție**, ca fiind o valoare numerică, P_{aj} , exprimând gradul de potrivire prezis pentru un anumit articol, $i_j \notin I_{ua}$ pentru utilizatorul actual, u_a . Această valoare prezisă este inclusă în aceeași scară (ex. de la 1 la 5) ca și valorile furnizate de utilizatorul u_a .
- **recomandare** constând dintr-o listă de k articole, $I_r \subset I$, pe care utilizatorul activ le va plăcea cel mai mult. Lista de articole recomandate trebuie să cuprindă articole care încă nu au fost achiziționate de utilizatorul activ, adică $I_r \cap I_{ua} = \emptyset$. Acest tip de algoritmi de filtrare colaborativă este cunoscută și ca "*Top-N recommendation*" (Sarwar și alții., 2001).

Algoritmii CF reprezintă totalitatea datelor utilizator-articol sub forma unei matrice de

evaluare, A , de dimensiune $m \times n$. Fiecare element $a_{i,j}$ reprezintă scorul de preferință (evaluarea) celui de-al i -lea utilizator acordat articolului j . Fiecare evaluare este o valoare numerică și poate fi nulă, reprezentând faptul că acest utilizator nu a evaluat încă produsul respectiv.

Algoritmii CF pot fi împărțiți în două categorii principale: *Memory-based* (bazat pe utilizator) și *Model-based* (bazat pe articol) (Badrul și alții., 2001).

OPORTUNITĂȚI PENTRU COMERȚUL ELECTRONIC

Sistemele de recomandare reprezintă o modalitate de personalizare automată a site-urilor de comerț electronic. Importanța lor va crește, deoarece afacerile moderne se concentrează tot mai mult pe valoarea pe termen lung a clienților lor.

Site-urile de comerț electronic vor trebui să dezvolte relații cât mai strânse cu clienții lor. Marketingul prin comerț electronic va duce la redefinirea marketingului relațiilor și a efectului acestuia asupra satisfacției consumatorului (McCarthy&Aronson, 2001). De vreme ce reținerea clienților va fi foarte importantă pentru site-uri, această relație va trebui să aducă beneficii clientului. Unul din principalele direcții în desfășurarea activității pe Internet o reprezintă dezvoltarea unei baze de date cuprinzătoare care să conțină informații detaliate despre clienții actuali și cei potențiali. Aceasta bază de date le va permite companiilor să dezvolte produse și servicii care întrunesc așteptările fiecărui individ în parte. Legat de acesta, se vor ivi provocări importante, mai ales de ordin etic (Schafer și alții. 1999).

Deși se ivesc nenumărate provocări importante, ne putem aștepta la dezvoltarea și răspândirea continuă a sistemelor de recomandare, a bazelor de date cuprinzătoare și a sistemelor care analizează obiceiurile/comportamentul consumatorului, indiferent de industrie. Acest trend al dezvoltării și răspândirii este confirmat de faptul că în ultimii 20 ani lista celor mai mari companii din lume s-a remaniat complet. Mijlocul anilor '90 era dominat de companii de producție-fabricație și de industria petrolieră (General Electric, Royal Dutch Shell, Exxon Mobil, Toyota etc.), iar în ziua de azi topul 5 al celor mai mari companii este Apple Inc, Alphabet (Google), Microsoft, Amazon Inc. și Facebook (Tabel 1).

Este bine cunoscut faptul că activitatea de bază ale acestor companii este comerțul electronic (e-commerce), iar sistemele de recomandare, bazele de date cuprinzătoare și sistemele care analizează obiceiurile/comportamentul consumatorului – toate din cele enumerate având scopul de a dezvolta o bază de clienți durabile și de încredere – sunt accesoriile indispensabile ale acestuia.

În prezent companiile folosesc mai multe variante de sisteme de recomandare. Am amintit mai multe tehnologii folosite, precum și ce tip de informații folosesc diferitele tipuri de sisteme. (Avornicului, 2010)

Totuși, există încă multe posibilități de extindere a sistemelor de recomandare în site-urile de comerț electronic. Multe site-uri folosesc datele despre comenzile precedente ca și evaluări pozitive implicite. Însă puține site-uri încearcă să extragă evaluări implicite negative pornind de la informațiile de cumpărare. O posibilitate, sugerată în (Schafer și alții, 1999), ar fi analiza datelor referitoare la produsele returnate. În timp ce un client poate să returneze un articol dintr-o varietate de motive, în general orice returnare poate fi luată în considerație ca evaluare negativă pentru articolul în discuție.

Alt model discutat în (Schafer și alții, 1999) propune aprecierea produselor pe baza detaliilor vizualizate de către clienți. Dacă site-ul oferă posibilitatea vizualizării mai multor detalii referitoare la produse, măsura în care utilizatorii vor fi interesați de aceste detalii poate oferi informații despre aprecierea pozitivă sau negativă a unui anumit produs.

Mulți algoritmi ale sistemelor de recomandare care folosesc atât evaluări pozitive, cât și negative, sunt mai performanți (Schafer și alții 1999, Silaghi 2005), deci evaluările negative devin valoroase.

Sistemele de recomandare pot fi folosite atât în rol de vânzător virtual, cât și ca instrument de marketing. Folosind corelări de tip persoană la persoană se pot determina segmente de piață pentru campanii de marketing eficiente. (Gubán, 2008)

Sistemele de recomandare care sprijină nivelul de marketing al unei organizații, ajutând mediul de marketing și de marketing managerii companiei, se numesc Marketing Recommender Systems (MkRS).

Majoritatea MkRS-urilor sunt sisteme automatizate care nu necesită nici un efort manual din partea utilizatorului, baza funcționării lor este categorizarea. Tehnica categorizării identifică utilizatorii cu preferințe similare. Când grupurile sunt create, predicțiile individului se pot anticipa pe baza mediei opiniilor altora din același grup. Câteva dintre grupuri reprezintă fiecare utilizator prin prezența lor în alte grupuri. Predicția, deci, este media dintre grupuri, ponderată în funcție de gradul de participare. Tehnica categorizării produce, de obicei, recomandări mai puțin personale decât celelalte metode și de cele mai multe ori rezultă în precizitate mai scăzută decât algoritmul celui mai apropiat vecin (nearest neighbor algorithms). Totuși, aceste diferite grupuri se pot folosi drept ca grupurile țintă ale campaniilor marketing, deoarece dacă profilul unui client nu corespunde în totalitate cu profilul cumpărătorilor

anteriori, este destul de aproape de acesta și are probabilitate mult mai mare să fie interesat de produsele companiei decât un potențial cumpărător întâmpinat pe stradă.

Cele mai bune și complexe obiective MkRS sunt reflectate pe trei nivele: obiectivele de input, scopurile și obiectivele de procesare a datelor și ca un set, de acestea sunt reflectate în:

- Recomandarea consumatorilor cu privire la calitatea producției organizației (calitatea produsului)
- Recomandarea clienților privind îmbunătățirea ofertei organizațiilor (dezvoltarea de chestionare)
- Utilizați motoarele de căutare ca urmare a recomandărilor făcute de către clienți
- Elaborarea rapoartelor de vânzări, ca urmare a recomandărilor clienților
- Identificarea cauzelor care stau la baza de nemulțumirilor clienților din cauza nerecomandărilor de produse

Ca sisteme cibernetice, MkRS intenționează eliminarea perturbațiilor, menținând stabilitatea într-o condiționare continuă, având scopul de a alege decizia cea mai potrivită (Zheng și alții, 2015).

În tabelul 2 putem vedea câteva exemple de MkRS, comparate pe baza unor caracteristici fundamentale, identificate de autori.

Mai mulți autori, de exemplu H. Krallmann în (Krallmann și alții., 2003), consideră că ar trebui să ne propunem construirea celui mai bun posibil serviciu automatizat de recomandare. Alții susțin că un sistem care necesită un efort manual din partea utilizatorilor este mai potrivit, argumentând că sistemele care necesită inputuri din partea clienților creează o relație cu aceștia. Dacă crearea relației necesită un efort manual de la clienți, ei vor prefera să se întoarcă la siteul în care au investit efort, sporind gradul de persistență a relației dintre site și clienții lui.

Noi susținem această opinie, adăugând și dimensiunea de colaborare cu alți clienți ai site-ului. Adică, un utilizator, pe lângă faptul că introduce date despre preferințele personale, prin care sistemul de recomandare îi poate oferi recomandări mai pertinente, poate apela la alți utilizatori cu aceleași gusturi, pentru a afla opinia lor. Aceste opinii considerăm că sunt deosebit de utile în momentul luării unei decizii de cumpărare. În plus, aceste legături cu alți membri ai comunității virtuale contribuie la fidelizarea clientului, un aspect pe care se pune tot mai mult accent. Contribuie de asemenea la accentuarea “feței umane” a web-ului.

CONCLUZII

Companiile zilelor noastre trebuie să adopte un nou model de afaceri, care pune accentul pe valoarea unei relații îndelungate cu clientul. Modelul poate fi realizat prin integrarea unor noi inițiative Internet și aplicații Web, incluzând și sistemele de recomandare.

Sistemele de recomandare sunt instrumente folosite în aplicațiile de comerț electronic care aduc beneficii atât clienților cât și comercianților. Aceste sisteme oferă suport utilizatorilor pentru a găsi articole de care ei sunt interesați și ajută comercianții să sporească vânzările.

În acest articol am analizat sistemele de recomandare existente. Considerăm deosebit de importantă crearea de instrumente online care să le permită consumatorilor să acceseze cât mai ușor informații despre produse, să comunice cu alte grupuri, să facă propuneri.

REFERINȚE

- [1] Avornicului M., (2010). Informatikai rendszerek tervezése és menedzsmentje, Kolozsvár, *ÁBEL Kiadó*, Kolozsvár
- [2] Badrul S., George K., Joseph K., John R. (2001). Item-based Collaborative Filtering recommendation Algorithms, <http://www10.org/cdrom/papers/519/sdm2.htm>
- [3] Gubán Á., Kása R. (2013). Service Logistics: Logistification of service processes, *ADVANCED LOGISTIC SYSTEMS: THEORY AND PRACTICE* 7:(1), 43–50.
- [4] Gubán M. (2008). Megrendelés vezérelt virtuális szerelő és kiszolgáló központok kialakításának egy matematikai modellje, In: Radványi Tamás (szerk.) *Üzlet és Tudomány: Dolgozatok a BGF Pénzügyi és Számviteli Kara tudományos műhelyéből*, 204–212
- [5] Kovács Gy. (2007). E-mall în spațiul economic virtual, *Editura Risoprint*, Cluj-Napoca
- [6] Schafer J. B., Konstan J., Riedl J. (1999). Recommender Systems in E-Commerce, *ACM Conference on Electronic Commerce*
- [7] Schafer J. B., Konstan J., Riedl J. (2001). E-Commerce Recommendation Applications, *Data Mining and Knowledge Discovery*
- [8] Zheng S., Zheng W., Jin X. (2015). An Intelligent Recommendation System based on Customer Segmentation, *International Journal of Research in Business Studies and Management*, Volume 2, Issue 11, 78–90

Tabel 1 – Cele mai mari companii din lume între 1997–2016 (în milioane de USD)

Loc	1997	2001	2006	2011	2016 (Septembrie)
1	General Electric	General Electric	Exxon Mobil	Exxon Mobil	Apple Inc
	222,748	372,089	446,943	406,272	612,662
2	Royal Dutch Shell	Microsoft	General Electric	Apple Inc.	Alphabet
	191,002	326,639	383,564	376,41	541,7
3	Microsoft	Exxon Mobil	Microsoft	PetroChina	Microsoft
	159,66	299,82	293,537	276,844	448,223
4	Exxon Mobil	Wal-Mart	Citigroup	Royal Dutch Shell	Amazon Inc.
	157,97	273,22	273,691	236,677	401,629
5	The Coca-Cola Company	Citigroup	Gazprom	ICBC	Facebook
	151,288	255,299	271,482	228,168	368,704
6	Intel Corporation	Pfizer	Industrial and Commercial Bank of China	Microsoft	Exxon Mobil
	150,838	249,021	254,592	218,38	363,175
7	Nippon Telegraph and Telephone	Intel Corporation	Toyota Motor Corporation	IBM	Berkshire Hathaway
	146,139	203,838	241,161	216,724	357,138
8	Merck	BP	Bank of America	Chevron Corporation	Johnson & Johnson
	120,757	200,794	239,758	211,893	325,366
9	Toyota Motor Corporation	Johnson & Johnson	Royal Dutch Shell	Wal-Mart	General Electric
	116,585	197,912	225,781	204,659	266,42
10	Novartis	Royal Dutch Shell	BP	China Mobile	Tencent
	104,468	189,913	218,643	196,148	260,899

Sursa: Prelucrare pe baza datelor din Financial Times

Tabel 2 – Exemple de sisteme de MkRS

	Happiest Mind	Bridgewell	Zoho SalesIQ	Nosto
Analiza comportamentului clienților pe site-urile de e-commerce	DA	DA	DA	DA
Proгноză asupra comportamentului consumatorului	NU	DA	DA	NU
Recomandarea produselor pe baza traiectoriei căutării	NU	DA	NU	NU
Recomandare personalizată direct pentru individ	NU	NU	NU	DA
Integrare cu rețele sociale	DA	NU	NU	NU
Integrare cu sisteme de CRM	DA	DA	DA	NU
Posibilități de campanie de e-mail marketing	DA	NU	DA	DA

Sursa: Prelucrare pe baza datelor furnizate de site-urile soluțiilor prezentate

Figura 1 Modelul unui sistem de recomandare

