

SISTEMA DE RECOMENDAÇÃO DE PRODUTOS EM MARKETING COM USO DE MÉTODOS DE APOIO À DECISÃO

Miguel A. G. Pinto, Ricardo Tanscheit, Marley Vellasco

Departamento de Engenharia Elétrica – Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio)
miguel@novelbiz.com.br, tanscheit@puc-rio.br, marley@puc-rio.br

Resumo – Em um mercado tão competitivo como o atual, existem alguns fatores que fazem a diferença e que tornam uma empresa líder de mercado em detrimento de outras. O mercado eleva a empresa ao sucesso, estabelece os critérios de procura de produtos e define ou redefine necessidades. E por isso compreendê-lo é tão importante. O sucesso nos negócios não é determinado pelo produtor, mas pelo consumidor, cada vez mais exigente e diversificado. Para auxiliar o gestor a compreender seu mercado, existem técnicas de marketing, que prezam a busca por segmentos de consumidores e o posicionamento de produtos para aumentar a sua chance de compra. As empresas de varejo virtual estão diante de desafios cada vez maiores na recomendação de produtos a clientes, em virtude do aumento da concorrência e de um grande número de novos usuários do mercado online. Neste contexto, o presente artigo aborda o uso de um filtro colaborativo hibridizado com números fuzzy para melhorar a desempenho de recomendadores em lojas online.

Palavras-chave – Recomendação, Marketing, Números Fuzzy, Filtros Colaborativos.

1 Introdução

Atualmente, uma empresa não concorre apenas com as lojas próximas, mas com empresas em todo o mundo, acessíveis pela internet. A internet traz vantagens enormes a uma empresa, pois permite que uma loja virtual alcance uma base de clientes enorme e variada, sem limites de fronteiras ou distâncias. Também permite que uma empresa tenha uma variedade enorme e diversificada de produtos a venda.

Se, no início da internet, as primeiras lojas virtuais puderam prosperar praticamente sem concorrentes, hoje elas devem competir com gigantes virtuais por fatias de mercado. É bem conhecido o fato de que consumidores online são impacientes e a diferença entre fazer o cliente comprar em uma dada loja ou visitar a próxima está muitas vezes em fazer com que a melhor oferta esteja na frente do cliente antes que ele abandone a página de internet desta loja.

Se, por um lado, ofertar o produto certo ao consumidor é a chave para o sucesso na venda, muitos dos sistemas existentes para recomendação para visitantes online são pouco eficazes no que diz respeito a novos visitantes, que podem possuir pouco conhecimento sobre os produtos e categorias a sua disposição e para os quais poucas informações estão disponíveis. Sistemas recomendadores baseados em filtros colaborativos e de informação [1][2], que são agentes que usam informação de comportamento ou preferência para filtrar alternativas e propor recomendações ao usuário [3], poderiam trazer uma solução. Porém, tais sistemas requerem informação sobre as preferências dos visitantes, como avaliações de produtos, preferências implícitas inferidas de comportamentos do consumidor frente ao navegador ou histórico de compras. Isto os torna pouco práticos para visitantes novos.

Sistemas de suporte à decisão de consumidores (SSDC) oferecem, potencialmente, soluções alternativas. SSDC é um sistema que conecta a empresa a seus consumidores potenciais ou existentes, provendo suporte para parte do processo de tomada de decisão do consumidor. Desenvolvedores supõem que, ao simplificar informações do produto, usuários de SSDC são capazes de comparar alternativas, avaliá-las mais a fundo e então tomar melhores decisões [4]. A maioria dos SSDCs assume que o consumidor está disponível e capacitado para comparar alternativas que são relevantes e importantes para eles.

A proposta deste trabalho é desenvolver um novo algoritmo de recomendação que explore ao máximo a união de tecnologias presentes de recomendação (SSDC e filtros colaborativos) e de conceitos oriundos da teoria de marketing para que cada algoritmo compense as eventuais fraquezas dos outros.

Os modelos propostos nesse trabalho combinam os paradigmas de modelagem por números fuzzy, conceitos de posicionamento de produtos oriundos da teoria de marketing e filtros colaborativos de produtos. O sistema resultante é capaz de oferecer resultados iniciais para produtos e usuários novos e se adaptar ao longo do uso aos padrões de consumo existentes.

2 Filtros Colaborativos

Diversas empresas no setor de varejo investem significativamente na formação de bancos de dados de clientes e de compras. No caso de lojas virtuais, este investimento é ainda mais pronunciado devido ao fato de bancos de dados fazerem parte da própria operação. Juntamente com o investimento no armazenamento de dados, têm sido formulados algoritmos para aproveitar o volume de dados armazenados e gerar resultados para as empresas. Filtros Colaborativos (FC) [5][6] constituem-se em uma técnica bem sucedida em diversas aplicações de recomendação, buscando similaridades em hábitos dos usuários para prever suas decisões futuras.

Filtragem colaborativa é o processo de filtrar informação ou padrões usando técnicas que envolvem colaboração de múltiplos agentes, pontos de vista, fontes de dados, etc. Filtros colaborativos funcionam construindo uma base de dados de preferências de itens para usuários. Um novo usuário é comparado a uma base de dados de forma a descobrir vizinhos, os quais são outros usuários que possuem características similares. Os itens de interesse para esses usuários vizinhos são então recomendados ao usuário inicial.

O Filtro Colaborativo é baseado na premissa de que, se dois usuário X e Y tiverem interesses similares, refletidos em votos similares com relações a n itens, então os usuários irão demonstrar da mesma forma sua similaridade de interesses com relações a outros itens [7]. O Filtro Colaborativo (FC) pode obter opiniões dos usuários com relações a itens de forma explícita, como votações feitas pelos usuários, ou de forma implícita, a partir de históricos de compra [8].

O objetivo de um algoritmo para filtragem colaborativa é sugerir novos itens ou prever a utilidade de um determinado item para um usuário em particular com base nas preferências anteriores do usuário ou nas de usuários semelhantes. Em um cenário típico de uso de um FC, considere-se uma lista de m usuários $U = \{u_1, u_2, \dots, u_m\}$ e uma lista de n itens $I = \{i_1, i_2, \dots, i_n\}$. Cada usuário u_i possui uma lista de itens I_{ui} para os quais expressou seu interesse. É importante notar que $I_{ui} \subset I$ e que é possível que I_{ui} seja um conjunto nulo. Existe um usuário distinguível $u_a \in U$, denominado usuário ativo, para o qual é tarefa do algoritmo de filtro colaborativo encontrar um item de interesse, em particular buscando recomendações. Assim, haverá uma lista de N itens, $I_r \subset I$, pelos quais o usuário ativo vai mais se interessar. Note que a lista recomendada deve ser de itens ainda não comprados pelo usuário ativo, i.e., $I_r \cap I_{ua} = \emptyset$. Esta interface dos algoritmos FC é também conhecida como recomendação Top-N.

Nos algoritmos de filtragem colaborativa, as técnicas mais populares são baseadas em memória e utilizam toda a base de dados de usuários e itens para gerar a predição. Essas técnicas, também conhecidas como vizinhança mais próxima ou filtragem colaborativa baseada em memória, são mais populares e vastamente utilizadas na prática, inclusive em aplicações comerciais como Amazon e Barnes & Noble, devido a sua facilidade de implementação e alta efetividade [9][10].

Destacam-se, entre as técnicas de filtragem colaborativa baseadas em memória, o método baseado em item, que observa o conjunto de itens que o usuário-alvo avaliou previamente, computa quão similares são eles com relação a um item-alvo i e então seleciona os k itens mais similares $\{i_1, i_2, i_3, \dots, i_k\}$. Ao mesmo tempo, as suas similaridades correspondentes $\{s_1, s_2, s_3, \dots, s_k\}$ também são computadas. Encontrados os itens mais similares, a predição é então computada considerando-se a média ponderada das avaliações do usuário-alvo com relação aos itens similares [11].

Um ponto crítico no algoritmo de FC baseado em itens é computar a similaridade entre itens e selecionar os mais semelhantes. A idéia básica no cálculo de similaridade entre dois itens i e j é, primeiramente, isolar usuários que tenham avaliado esses itens e então aplicar a técnica de cálculo de similaridade para determinar a similaridade s_{ij} entre eles. A Figura 1 apresenta o processo, onde as linhas da matriz representam usuários e as colunas, itens.

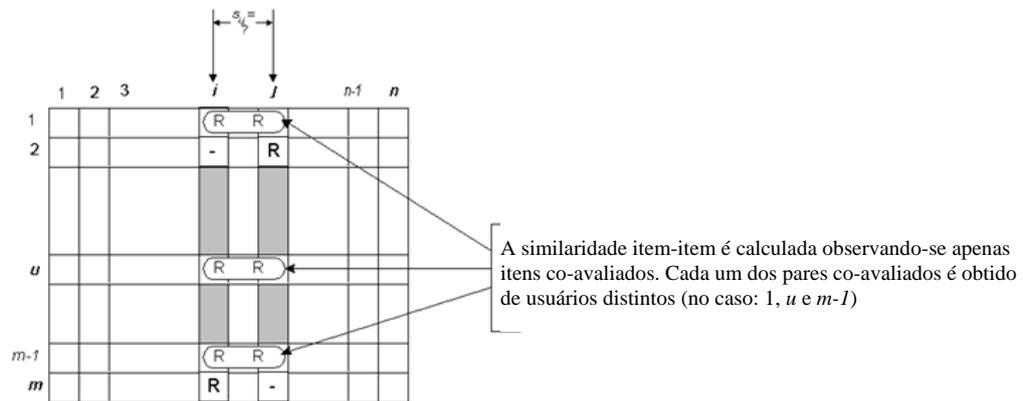


Figura 1. Isolando itens co-avaliados e cálculo de similaridade

O algoritmo de FC necessita de uma forma de comparar itens de forma a descobrir aqueles mais próximos entre si. A similaridade por cosseno de vetor considera os vetores de avaliação entre dois itens com os quais se quer avaliar a similaridade. Seja A a matriz $m \times n$ usuário-item; então, a similaridade entre dois itens i e j é definida pelo cosseno entre os vetores de dimensão n correspondentes à i -ésima e à j -ésima coluna da matriz A . A similaridade por cosseno entre itens $i = \{i_1, i_2, \dots, i_n\}$ e $j = \{j_1, j_2, \dots, j_n\}$ é dada por:

$$w_{i,j} = \cos(\vec{i}, \vec{j}) = \frac{\vec{i} \cdot \vec{j}}{\|\vec{i}\| \|\vec{j}\|} = \frac{i_1 j_1 + i_2 j_2 + \dots + i_n j_n}{\sqrt{i_1^2 + i_2^2 + \dots + i_n^2} \sqrt{j_1^2 + j_2^2 + \dots + j_n^2}} \quad (1)$$

onde “.” denota o produto escalar entre ambos os vetores [12].

Filtros colaborativos têm sido bem sucedidos em pesquisas e na prática, em aplicações em *e-commerce* e filtragem de informações. Porém, ainda existem importantes desafios a serem pesquisados no uso de filtros colaborativos para sistemas de recomendação. Em aplicações reais de filtragem colaborativa, os bancos de dados terão uma quantidade extremamente grande de usuários e itens diversificados, de forma que dificilmente um usuário terá avaliado uma quantidade substancial de itens. Do ponto de vista das necessidades de negócio, do recomendador é demandado ter velocidade alta, acurácia e trazer lucro para as empresas que o empregam. Dentre os desafios podem-se destacar: esparsidade e escalabilidade dos dados, sinônimos (itens com o mesmo nome na base de dados), ovelha cinza (item ou usuário novo não avaliado no treinamento do FC).

3 Marketing e Filtragem por Números Fuzzy

Quando as empresas desenvolvem um novo produto (ou item), elas utilizam técnicas existentes desde a década de 40 para definir suas características. São técnicas de marketing que buscam dar valor a um nicho de mercado que possui características próprias baseadas em posicionamento. A criação de um posicionamento para um produto requer conhecimento dos interesses e preferências de um grupo de consumidores e capacidade de transformá-los em números, ajustando a quantidade de aspectos de valor com o valor máximo que os consumidores estariam dispostos a aportar por esse produto.

O processo de marketing para criação de produtos passa pela segmentação, seleção e posicionamento, constituindo-se em um processo em três estágios (Figura 2). Determina-se, primeiramente, que tipos de consumidores existem, para então selecionar os que a empresa tem melhor condições de servir. Finalmente, implementa-se uma segmentação otimizada de produtos e serviços, de forma a distinguir a empresa de outras presentes no mercado.

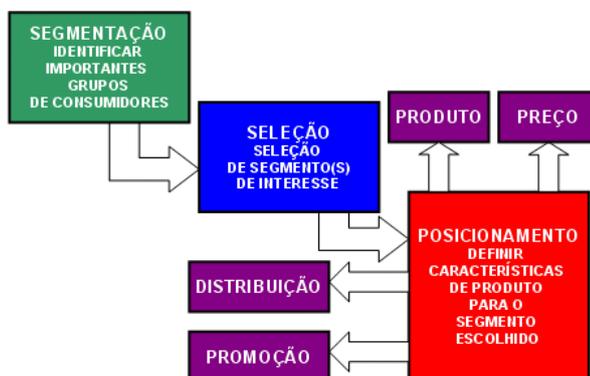


Figura 2 – Segmentação, Seleção e Posicionamento

O método de filtragem colaborativa ignora esse processo que compreende desde a criação do posicionamento do produto até a formação de suas características individuais. A filtragem colaborativa apenas leva em conta a proximidade entre usuários ou itens, causando problemas quando o usuário não possui avaliações suficientes.

Recomendadores baseados em conteúdo, por outro lado, utilizam de métodos heurísticos e algoritmos de classificação para fazer suas recomendações [13]. As técnicas baseadas em conteúdo possuem um problema de inicialização que difere do problema de mesmo nome nos filtros colaborativos. Enquanto na filtragem colaborativa o problema é de um usuário novo que tenha avaliado poucos itens (ou itens novos pouco avaliados), o problema de inicialização em técnicas baseadas em conteúdo ocorre quando há poucas informações de conteúdo para serem analisadas. Eles também são limitados à presença de características explicitamente associadas aos objetos que recomendam, muitas vezes necessitando de opiniões de especialistas ou de informações não presentes.

O recomendador baseado em conteúdo proposto por Hosseinpour [14], que tem relação direta com os conceitos de marketing e é de fácil hibridização com um filtro colaborativo, faz uso de números fuzzy e características do produto como bases de recomendação. Os números fuzzy, aqui considerados como triangulares, podem ser vistos como distribuições de possibilidade e são denotados por, $\tilde{p} = (p_1, p_2, p_3)$ com função de pertinência $\mu_{\tilde{p}}(x)$, onde p_1, p_2 e p_3 são números reais tais que $p_1 \leq p_2 \leq p_3$.

Todo item a ser recomendado pode ser definido como possuindo um conjunto de características técnicas que o diferencia unicamente de outros itens da mesma categoria. Na metodologia proposta, as diversas *características técnicas* que distinguem itens entre si numa mesma categoria devem ser transformadas em *componentes* que tenham algum valor para os usuários. Para a avaliação dos componentes, definem-se sete números fuzzy, representados na Figura 3, aos quais são associados os termos lingüísticos muito baixa (MuB), baixa (B), média baixa (MeB), média (Me), média alta (MeA), alta (A) e muito alta (MuA).

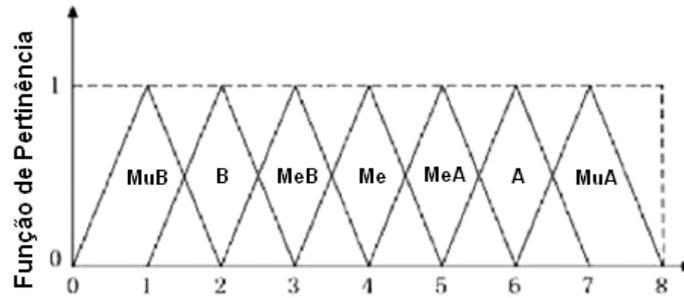


Figura 3 – Função de Pertinência para números fuzzy triangulares

Considera-se que cada item I_i é representado por um vetor \tilde{P}_i com n componentes relativos àquele item. O mesmo item I_i possui outro vetor E_i composto pelas especificações técnicas que o diferenciam de outros itens da mesma linha. Cada componente $p_i \in \tilde{P}_i$ é composto por um vetor de especificações $\tilde{E}_p = (\tilde{e}_p^1, \tilde{e}_p^2, \dots, \tilde{e}_p^k)$, onde cada especificação funcional \tilde{e}_p^i é um número fuzzy triangular que representa a capacidade de esta especificação do produto afetar o componente. Como cada especificação técnica pode influir de forma distinta sobre o componente, pode-se considerar também um vetor de pesos $W=(w_1, w_2, \dots, w_k)$. É possível, então, calcular o valor de um componente como um número fuzzy triangular a partir de especificações técnicas:

$$p_i = \sum_{j=1}^k (e_i^j \times w_j^i) \quad (2)$$

O vetor de componentes $\tilde{P}_i = (\tilde{p}_1, \tilde{p}_2, \dots, \tilde{p}_n)$ é formado por números fuzzy triangulares que representam cada qual um componente do produto e que podem ser utilizados para comparações dos interesses de valor do cliente.

No método proposto por Hosseinpour, o usuário define o conjunto de componentes que ele busca no item que lhe será recomendado, sendo cada componente um número fuzzy, conforme descrito anteriormente. Ao mesmo tempo, os diversos itens possuem seus componentes definidos como números fuzzy a partir das especificações, de forma a poderem ser comparados com o conjunto de componentes definido pelo usuário. A comparação entre dois números fuzzy é realizada calculando-se a compactação próxima de ambos.

Suponha-se que um usuário defina o componente para um item de seu interesse como $\tilde{q}_B = (q_B^1, q_B^2, q_B^3)$ e que exista um item que possua como valor para o mesmo componente o número fuzzy $\tilde{q}_A = (q_A^1, q_A^2, q_A^3)$. O cálculo da similaridade entre ambos (por meio da compactação próxima) é dado por:

$$N_E(\tilde{q}_A, \tilde{q}_B) = 1 - \frac{1}{\sqrt{3}} \left(\sum_{j=1}^3 |q_A^j - q_B^j|^2 \right)^{1/2} \quad (3)$$

A partir da equação acima, é possível efetuar uma comparação entre os interesses de um cliente por todos os produtos disponíveis à venda, com base no valor que cada produto oferece ao cliente por meio dos componentes. Quanto menor o valor de $N_E(\dots)$, mais próximo o item analisado está dos interesses do cliente.

4 Sistema Híbrido FC-Fuzzy

O algoritmo baseado em números fuzzy descrito no capítulo anterior se assemelha ao processo de posicionamento em marketing, se cada componente for considerado como um posicionamento. Dessa forma, podem-se gerar posicionamentos baseados nas especificações e considerando que usuários parecidos compram itens com posicionamentos semelhantes. É possível, também, efetuar comparações diretas entre itens com base em posicionamentos semelhantes.

O algoritmo de filtragem colaborativa baseados em memória tem como principais problemas a perda de desempenho em dados esparsos e a recomendação de itens e usuários novos. O método de recomendação por posicionamento fuzzy, por sua vez, possui algumas desvantagens a ser consideradas: necessidade de um especialista para gerar os posicionamentos com base nas especificações dos itens; ter sido desenvolvido para itens de uma mesma categoria, o que impede recomendações cruzadas entre itens de categorias diferentes; suposição de que o usuário definirá o seu tipo de posicionamento para efetuar a recomendação.

Como o algoritmo de recomendação por posicionamento fuzzy não prevê recomendações entre categorias distintas, a possibilidade de utilizar combinação de similaridades entre ambos os algoritmos se torna mais difícil. Como o filtro colaborativo não apresenta problemas de recomendar entre categorias, a opção de utilizá-lo primeiramente apresenta-se como a

mais viável. Assim, propõe-se que os dois algoritmos sejam utilizados em cascata, de forma que o filtro colaborativo efetue a escolha da categoria a ser considerada e o método de recomendação fuzzy tome a decisão final quanto ao item a ser comprado.

O algoritmo de recomendação final proposto nesse artigo escolhe os itens em duas fases. Primeiramente, um FC Item-Item é utilizado para definir a categoria que será recomendada. Dado que este primeiro filtro colaborativo define categorias, e não itens, ele foi nomeado “FC Categoria”. Selecionada a categoria pelo primeiro filtro, o algoritmo de posicionamento fuzzy recomenda o item mais apropriado dentre todos da categoria.

O algoritmo de posicionamento fuzzy proposto por Hosseinpour necessita que o usuário defina seus posicionamentos manualmente, o que é pouco prático para recomendadores comerciais. Para permitir que o algoritmo possa efetuar a recomendação usando apenas o histórico de compras do usuário, utilizam-se os posicionamentos fuzzy dos itens comprados para inferir o posicionamento do usuário e permitir o cálculo de similaridade com os itens disponíveis para recomendação. O algoritmo final proposto neste artigo passa a ser chamado de “FC Híbrido Categoria-Fuzzy”.

5 Experimentos

Para avaliação do algoritmo foi criada uma base de dados experimental, com dados representativos do mercado de *e-commerce* brasileiro. Foram especificadas as quantidades de clientes, itens e compras, bem como as categorias dos itens, com seus posicionamentos e regras de criação.

Os experimentos foram desenvolvidos em uma base com vinte mil clientes representando as características demográficas da população brasileira obtidas pelo censo demográfico do IBGE de 2002. Foram definidas quatorze categorias de itens e, para cada uma delas, foram desenvolvidos um conjunto de especificações técnicas e seus respectivos posicionamentos. No total, foram criados 1000 itens para cada categoria, com especificações técnicas geradas aleatoriamente, originando uma ampla gama de posicionamentos. Com base em dados médios de compra de brasileiros no mercado de *e-commerce*, foram definidas sete compras por usuários, baseadas em suas características e nas especificações dos itens.

A utilização uma base de dados artificial permite uma avaliação do usuário para todos os itens, bem como uma liberdade de variação da esparsidade (aumento ou diminuição do número de usuários com relação ao número de itens disponíveis).

Sobre a base de compras foi treinado o FC Item-Item original, utilizando-se similaridade cosseno entre os vetores, considerando-se esparsidades diferentes da base de dados. O filtro colaborativo de categorias foi treinado também com similaridade cosseno.

Os itens foram comparados entre si com base na similaridade entre seus posicionamentos por números fuzzy. O treinamento foi realizado com 5000 usuários na base com maior esparsidade e com 20.000 usuários na menos esparsa.

Para avaliar os algoritmos top-N, foram utilizadas as métricas de precisão (*precision*) e revocação (*recall*). As seis primeiras compras de cada usuário formam o conjunto de treinamento (CTr), e as últimas, o conjunto de teste (CTe). A partir do conjunto de treinamento, cria-se um conjunto de recomendações (top-N), cujo tamanho se pode variar. Por fim, os itens que pertencem tanto a top-N como a CTe formam o conjunto de acertos (CA). As métricas são:

$$revocação = Re = \frac{|CTe \cap top-N|}{|CTe|} \quad (4)$$

$$precisão = Pr = \frac{|CTe \cap top-N|}{N} \quad (5)$$

A avaliação final é dada pela métrica F1:

$$F1 = \frac{2 * Pr * Re}{Pr + Re} \quad (6)$$

A Figura 4 apresenta os valores de F1 para filtros treinados em diversos níveis de esparsidade e para diversos valores de top-N. Avaliando-se os resultados, percebe-se que o FC Híbrido Categoria-Fuzzy apresenta desempenho significativamente superior ao do FC Item-Item, sobretudo para valores de N mais baixos. Dada a importância que usuários dão aos primeiros itens apresentados, essa característica se torna extremamente significativa.

Outra característica percebida do FC Híbrido Categoria-Fuzzy com relação ao FC Item-Item está no fato de o primeiro não apresentar variação significativa com mudanças de esparsidade da base dados, o que ocorre visivelmente com o FC Item-Item. Esta característica é especialmente útil em bases de dados reais.

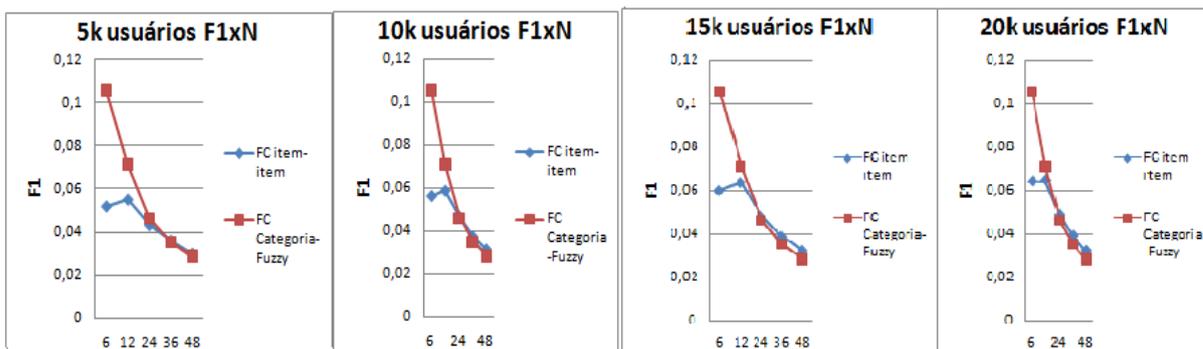


Figura 4 – Experimentos para diversos valores de top-N e treinamento em diversos níveis de esparsidade.

A Figura 5 apresenta uma análise do desempenho dos algoritmos de FC Item-Item, FC Híbrido Categoria-Fuzzy, FC de Categoria e Algoritmo Fuzzy Puro (considerando que a categoria sempre está certa) para diversos valores de Top-N, variando-se o número de compras feitas por cada usuário.

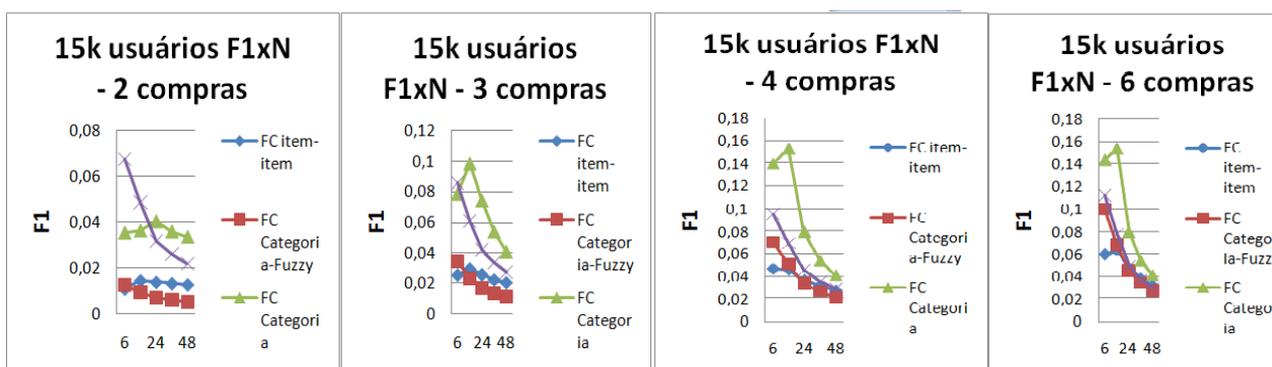


Figura 5 – Experimentos para diversos valores de top-N e alterando o número de compras feito por usuário (usando treinamento com 15 mil usuários).

A alteração do número de compras por usuário permite analisar o caso de “ovelha negra” (um usuário novo faz a primeira compra e o Filtro Colaborativo só possui essa compra para efetuar a recomendação). O desempenho de todos os algoritmos melhora com o aumento de compras, mas se percebe que o FC Híbrido Categoria-Fuzzy é inferior ao FC Item-Item para esse tipo de problema. Isto se deve principalmente ao baixo desempenho do FC de Categoria, que gera recomendações em categorias erradas, o que impossibilita o algoritmo de posicionamento fuzzy de acertar, pois todos os itens a serem recomendados estão na categoria que não será comprada.

Percebe-se que o algoritmo fuzzy puro apresenta desempenho superior ao do FC Item-Item em todos os casos, e que o FC Híbrido se aproxima do algoritmo fuzzy puro quando o desempenho do FC de Categoria melhora o que demonstra que esse primeiro algoritmo, parte da hibridização, é a causa do baixo desempenho para poucas compras.

6 Conclusões

A proposta deste trabalho foi desenvolver um novo algoritmo de recomendação que explorasse ao máximo a interação entre as tecnologias presentes de recomendação (SSDC e filtros colaborativos) e os conceitos oriundos da teoria de marketing. Os resultados desta interação mostraram-se promissores, justificando a proposta do trabalho. O Filtro Categórico (que é um filtro colaborativo) ofereceu ao Filtro Fuzzy (que é um SSDC) a possibilidade de recomendar itens em categorias distintas, enquanto que o Filtro Fuzzy permitiu uma maior precisão na recomendação do item dentro da própria categoria. Cada algoritmo hibridizado compensou as fraquezas do outro como originariamente se previra.

Os modelos propostos nesse trabalho combinaram os paradigmas de modelagem por números fuzzy, conceitos de posicionamento de produtos oriundos da teoria de marketing e filtros colaborativos de produtos. O sistema resultante apresentou um desempenho superior ao do Filtro Base, gerando resultados satisfatórios para uma diversidade de itens recomendados. O filtro proposto também demonstra invariância a esparsidade da base de dados, o que é de grande valor para grandes empresas varejistas.

Demonstrou-se também a viabilidade de utilização de um algoritmo híbrido em uma base de dados artificial; em trabalhos futuros estes mesmos algoritmos serão avaliados em uma base de dados real. Os filtros colaborativos já foram testados em bases deste tipo com sucesso; o algoritmo fuzzy puro de Hosseinpour foi testado com 70% de acerto nesse tipo de base de dados, de forma que se esperam resultados igualmente satisfatórios.

7 Referências

- [1] P. Resnick, H. R. Varian, Recommender systems, **Communications of the ACM**, 40 (1997), 56-58.
- [2] J.B. Schafer, J. A. Konstan, J. Riedl, E-commerce recommendation applications, **Data Mining and Knowledge Discovery**, 5 (2001).
- [3] A. Ansari, S. Essegai, R. Kohli, Internet recommendation systems, **J. Marketing Research**, 37 (2000), 363-375.
- [4] S. J. Hoch, D. A. Schkade, A psychological approach to decision support systems, **Manag. Science**, 42(1996), 51-64.
- [5] P. Resnick, P. N. Iacovou, M. Suchak, P. Bergstrom, J. Riedl, GroupLens and open architecture for collaborative filtering of netnews, **Proceedings of CSCW** (1994).
- [6] U. Shardanand, P. Maes, Social information filtering: algorithms for automating 'word of mouth', **Proc. CHI '84** (1995).
- [7] K. Goldberg, T. Roeder, D. Gupta, C. Perkins, Eigentaste: a constant time collaborative filtering algorithm, **Information Retrieval**, vol. 4(2001), no. 2, 133-151.
- [8] B. N. Miller, J. A. Konstan, J. Riedl, PocketLens: toward a personal recommender system, **ACM Trans. Information Systems**, 22(2004), 437-476.
- [9] G. Linden, B. Smith, J. York, Amazon.com recommendations: item-to-item collaborative filtering, **IEEE Internet Computing**, 7(2003), 76-80.
- [10] T. Hofmann, Latent semantic models for collaborative filtering, **ACM Trans. Information Systems**, 22(2004), 89-115.
- [11] G. Karypis, Evaluation of item-based top-N recommendation algorithms, **International Conference on Information and Knowledge Management** (2001), 247-254.
- [12] B. M. Sarwar, G. Karypis, J. A. Konstan, J. Riedl, Analysis of recommendation algorithms for e-commerce, **Proc. ACM E-Commerce** (2000), 158-167.
- [13] M. Pazzani, D. Billsus, Learning and revising user profiles: the identification of interesting web sites, **Machine Learning**, 27(1997), 313-331.
- [14] M. J. Hosseinpour, M. Mosalanezhad, I. Badrooh, M. Mojarad, An intelligent fuzzy-based recommendation system for consumer electronic products, **3rd Int. Conference on E-commerce with focus on Developing Countries**, (2008), 22-23.