

Adaptability in Recommendation Systems: perspectives

F.G. Cozman, M. R. Pereira-Barretto, W. J. Fuks

Abstract— Recommendation Systems and Navigation Systems are more and more helping in the search for the need thing on the Internet. This paper discusses possible applications of adaptability to them.

Keywords— Recommendation systems, Navigation Systems, Semantic Web.

I. INTRODUÇÃO

Sistemas de Recomendação têm sido utilizados principalmente em e-commerce, particularmente em lojas na Internet, sugerindo produtos relacionados aos que se está adquirindo ou com base no perfil do consumidor. Claramente, o interesse em seu desenvolvimento é o aumento das vendas. Outras aplicações envolvem a busca dirigida de conteúdo na Internet, podendo ser considerada como tecnologia associada à Web Semântica [3],[4]: indicações de páginas que contenham assuntos de interesse de uma pessoa, sem que esta pessoa as tenha buscado de forma ativa, considerando como ativa a busca que acontece quando se realiza buscas em um *engine* como Google. Estas ideias podem ser estendidas a outros domínios de recomendação, como a indicação de restaurantes, roupas, filmes, assuntos históricos ou outros.

De uma forma geral, os Sistemas de Recomendação visam a determinação de indicações que sejam de interesse da pessoa que navega. Uma visão mais recente incorpora a ideia de serendipidade (neologismo provindo do Inglês *serendipity*) [5]. Na Internet, o conceito está relacionado com o fato de que, durante a navegação, frequentemente encontra-se um link que leva a um assunto relacionado ou mesmo a um outro assunto fracamente associado ao assunto inicial, que atrai a atenção da pessoa que navega, fazendo-a passar a uma outra trajetória de navegação. Ao analisar-se a navegação, parece que foi realizada de modo fortuito, quase aleatório. Por este motivo, os Sistemas de Recomendação tem sido complementados ou substituídos por Sistemas de Navegação, que buscam exibir várias opções de continuação na busca. Assim, Sistemas de Recomendação não são idênticos a Sistemas de Navegação, embora o objetivo final seja semelhante: sugerir algo que seja do interesse daquele que navega na Internet.

Sistemas de Recomendação ou de Navegação contribuem para a construção de uma *user experience* que seja única, adaptada a cada pessoa, em cada momento. Sheryl Sandberg, COO do Facebook, escreveu que “sites que não forem customizados tornar-se-ão relíquia histórica”. Gigantes como Microsoft, Apple, Facebook e Amazon são conhecidos por serem “máquinas de predição de gostos” [6]. Cerca de 30% do faturamento da Amazon e 60% da Netflix provêm de Sistemas de Recomendação[6].

Entretanto, mesmo com este sucesso, as técnicas utilizadas, normalmente, não levam em conta a trajetória pessoal em cada momento; ao contrário, buscam a criação de agrupamentos (frequentemente estatísticos) ou formas de classificação de perfis de consumo que são gerais e não individuais. Este artigo propõe a utilização de técnicas adaptativas para a construção de uma experiência única e pessoal, ajustada ao momento de cada pessoa.

As próximas seções deste artigo estarão organizadas da seguinte maneira: na seção 2, faz-se uma breve descrição das estratégias correntes para a construção de Sistemas de Recomendação. Na seção 3, o conceito de adaptabilidade, como utilizado neste trabalho, é apresentado. Já na seção 4, formas de utilização do conceito de adaptabilidade são discutidas, bem como sua aplicação a Sistemas de Recomendação. Por fim, na seção 5 estarão as considerações finais.

II. SISTEMAS DE RECOMENDAÇÃO

A Fig.1 ilustra os principais tipos de Sistemas de Recomendação, utilizando-se da classificação feita por Ricci [7].




Figura 1. Principais tipos de Sistemas de Recomendação.

M. R. Pereira-Barretto, Escola Politécnica da Universidade de São Paulo (EP-USP), marcos.barretto@poli.usp.br

F. G. Cozman, Escola Politécnica da Universidade de São Paulo (EP-USP), fgcozman@usp.br

W. J. Fuks, Escola Politécnica da Universidade de São Paulo (EP-USP), william.fuks@gmail.com

Tem-se:

- sistemas baseados em filtragem colaborativa, que buscam realizar uma clusterização, agrupando usuários de comportamento semelhante, derivado a partir dos dados (de navegação na Internet, por exemplo).
- sistemas baseados em conteúdo, que buscam realizar uma indicação com base no histórico (de navegação, por exemplo).
- sistemas baseados em comunidades, que buscam realizar indicações a partir do comportamento dos “amigos” (em sentido amplo: pessoas que fazem parte da mesma comunidade).
- sistemas baseados em informações socio-demográficas, que são a tradição em estudos do comportamento do consumidor, determinando indicações a partir de comportamentos típicos de acordo com idade, classe social, estado civil, etc.
- sistemas baseados em expertise, que realizam indicações para problemas específicos como “ferramentas para conserto de encanamento”.
- sistemas híbridos, que utilizam duas ou mais abordagens, simultaneamente.

Os Sistemas de Recomendação baseados em filtragem colaborativa são os mais comuns [8] e podem ser utilizados como caracterização da generalização que, em geral, é buscada com as técnicas atuais. Em [8], os sistemas baseados em filtragem colaborativas são divididos em três categorias:

- baseados em memória (*memory-based*), que utilizam-se exclusivamente dos dados (de navegação, por exemplo)
- baseados em modelos (*model-based*), que utilizam-se de modelos de comportamento
- híbridos, que associam as técnicas acima ou ainda outras.

Estes sistemas utilizam-se de técnicas como as relacionadas na Fig. 1.

CF categories	Representative techniques
Memory-based CF	*Neighbor-based CF (item-based/user-based CF algorithms with Pearson/vector cosine correlation) *Item-based/user-based top-N recommendations
Model-based CF	*Bayesian belief nets CF *clustering CF *MDP-based CF *latent semantic CF *sparse factor analysis *CF using dimensionality reduction techniques, for example, SVD, PCA
Hybrid recommenders	*content-based CF recommender, for example, <i>Fab</i> *content-boosted CF *hybrid CF combining memory-based and model-based CF algorithms, for example, Personality Diagnosis

Figura 1. Técnicas de filtragem colaborativa [8].

Entre os modelos discutidos em [8], tem particular relação com o presente trabalho aqueles que se utilizam de modelos MDP (Markov Decision Process)[9], que vêem o problema de recomendação não como de predição mas como de otimização sequencial (“o que o usuário vai escolher em seguida?”).

Um processo de decisão de Markov é uma tupla $\langle S, A, T, R \rangle$ onde:

- S é um conjunto de estados em que o processo pode estar;
- A é um conjunto de ações que podem ser executadas em diferentes épocas de decisão
- T é uma função que dá a probabilidade de o sistema passar para um estado s_1 , dado que o processo estava no estado s_0 e o agente decidiu executar uma determinada ação a ;
- R é uma função que dá o custo (ou recompensa) por tomar a decisão de executar a ação a quando o processo está em um estado s_0 .

Uma aplicação de MDP a Sistemas de Recomendação encontra-se em [10], em que relata-se que o uso de um sistema baseado em MDP à loja de livros *online* Mitos, de Israel, produziu um resultado bastante superior que uma simples cadeia de Markov.

III. ADAPTABILIDADE

Neste trabalho, o conceito de adaptatividade está associado a Máquinas de Markov Adaptativas, utilizando-se a formulação em [11], baseada em [1],[2].

Uma máquina de Markov adaptativa M é definida por uma quintupla

$$M = (Q, S, T, q_0, F) \quad (1)$$

onde Q é um conjunto finito com n estados, S é o alfabeto de saída, q_0 é o estado inicial da rede e T é um conjunto de transições entre estados.

Tem-se F como um conjunto de funções adaptativas. Toda função adaptativa pertencente a F pode ser definida como uma quádrupla

$$f = (\Psi, V, G, C) \quad (2)$$

onde:

- Ψ é um conjunto de parâmetros formais ($\psi_1, \psi_2, \psi_3, \dots, \psi_m$);
- V é um conjunto de identificadores de variáveis ($v_1, v_2, \dots, v_n$), cujos valores são desconhecidos no instante de chamada de f mas que uma vez preenchidos terão seus valores preservados durante toda a execução da função;
- G é um conjunto de identificadores de geradores ($g_1^*, g_2^*, \dots, g_n^*$), variáveis especiais que são preenchidas com novos valores, ainda não utilizados pelo autômato, a cada vez que a função é chamada;
- C é sequência de ações adaptativas elementares executadas em f .

Cada transição γ_{ij} é caracterizada por:

$$\gamma_{ij} = (q_i, q_j, \rho_{ij}, p_{ij}, a_{ij}). \quad (3)$$

onde ρ é a probabilidade do estado q_j ser atingido estando em q_i .

Observe que cada transição γ_{ij} é única em T , isto é, não há duas transições diferentes partindo de um mesmo estado q_i e chegando a q_j . Além disso, seja Γ_q como o conjunto de todas as transições que se originam em um estado q . Então

$$\forall q \in Q, \sum_{\gamma \in \Gamma_q} \rho_\gamma = 1 \quad (4)$$

Isto é, a soma das probabilidades de todas as transições iniciando em q é exatamente um, para todo q pertencente a Q .

Tem-se a_{ij} como uma ação adaptativa da forma

$$a_{ij} = f(\omega_1, \omega_2, \dots, \omega_n) \cup \{\mathcal{E}\} \quad (5)$$

sendo f uma função adaptativa pertencente a F e ($\omega_1, \omega_2, \dots, \omega_n$) uma lista de argumentos que correspondem posicionalmente à lista de parâmetros Ψ declaradas para f . Finalmente, quando γ_{ij} é acionada, o símbolo $p_{ij} \in S \cup \{\mathcal{E}\}$ é inserido na cadeia de saída de $\mathcal{M}$.

Define-se um SMA (Sistema de Markov Adaptativo) como um conjunto de máquinas adaptativas de Markov que podem se relacionar através de novas ações adaptativas, introduzidas a seguir. Assim, pode-se estabelecer uma relação de escopo sobre as ações adaptativas definidas para cada máquina, classificando-as em: ações que modifiquem apenas a topologia local da máquina e ações que podem interferir no comportamento de outras máquinas pertencentes ao sistema.

Desta forma, cada máquina M^k pertencente a um sistema de Markov adaptativo é definida como uma quádrupla:

$$M^k = (Q^k, \Sigma, T^k, q_0^k, F^k) \quad (10)$$

onde Σ é o alfabeto de saída, comum a todas as máquinas do sistema, e Q^k, T^k, q_0^k e F^k são como na definição de Q, T, q_0 e F , respectivamente.

IV. ADAPTABILIDADE EM SISTEMAS DE RECOMENDAÇÃO

A aplicação de adaptabilidade em Sistemas de Recomendação será aqui discutida apenas no contexto de e-commerce, para que exemplos significativos e de fácil compreensão possam ser apresentados. Outras aplicações, como as indicadas na Introdução deste trabalho, podem ser extrapoladas a partir das discussões que se seguem.

Na busca por uma experiência pessoal e única, enfrenta-se de saída a questão da identificação do usuário na Internet: para oferecer uma experiência pessoal de navegação, é necessário saber-se quem está navegando. A tecnologia mais comumente utilizada para esta finalidade é o HTTP *cookie*, que fica armazenado no computador daquele que navega na Internet. Esta tecnologia é insuficiente para a determinação de quem está navegando, já que normalmente as pessoas navegam na Internet utilizando-se de dispositivos diversos como computadores pessoais e no trabalho, telefones móveis, tablets, etc. Além disso, substituem seus dispositivos a intervalos inferiores a 2 anos, fazendo com que, no médio prazo, perca-se o *cookie*. É raro fazer-se autenticação (*login*) para navegação. O fenômeno das redes sociais pode alterar esta situação, já que uma crescente quantidade de usuários da Internet mantém páginas pessoais em redes sociais, que exigem autenticação para acesso. Assim, a partir de serviços fornecidos pelas redes sociais, é possível ter-se a identificação única daquele que realiza a navegação. No restante deste trabalho, admite-se que seja possível identificar-se unicamente o usuário por intervalos longos de tempo, embora não sejam utilizadas informações pessoais como idade ou sexo.

As abordagens comumente empregadas em Sistemas de Recomendação, como exposto, determinam uma categoria, que é fixa no tempo. Assim, por exemplo, se um indivíduo é classificado como “comprador de livros de ficção científica”, o sistema tenderá a oferecer-lhe este tipo de produto ou, talvez, produtos correlatos como filmes de ficção científica. Entretanto, a vida de um indivíduo altera-se com o passar do tempo: livros de ficção científica podem ser acompanhados (ou substituídos) por livros sobre computação, significando talvez que um jovem ingressou no curso superior em Computação e alterou seus hábitos de consumo. Mais tarde (ou ao mesmo tempo), livros sobre culinária podem acompanhar (ou substituir) os anteriores, significando talvez que o universitário iniciou sua vida profissional e está morando sozinho, tendo agora a necessidade de cozinhar. Assim, há alterações no comportamento de consumo no longo prazo, causado pelos eventos que ocorrem na vida das pessoas, de forma geral: o ingresso na Universidade, o início da vida profissional, o (possível) casamento, a (eventual) chegada dos filhos, a mudança de casa, etc. Este aspecto pode ser chamado de “dinâmica de longa duração”: cada fase persiste durante meses ou até anos. Estas alterações de comportamento, entretanto, nem sempre são definitivas: possivelmente, um

interesse anterior pode ser ressuscitado: em um dado momento, um livro de ficção científica pode novamente atrair a atenção, dado que no passado o fez.

Por outro lado, tem-se “dinâmicas de curta duração iniciadas por data”, que duram dias e que aparecem na vida das pessoas em datas específicas como Dia dos Namorados, Dia das Mães, aniversário do(a) companheiro(a), aniversários de pais e amigos, etc. O conceito também se aplica ao consumo sazonal: busca-se por pacotes de férias mais provavelmente nos meses de janeiro, fevereiro e julho, por exemplo. Nestas datas, o comportamento altera-se: se normalmente há o interesse por livros de ficção científica, passa-se a buscar por presentes para a mãe, por exemplo. Note-se que há dinâmicas em que se conhece o instante em que podem ocorrer (por exemplo, proximamente ao Dia das Mães) e outras em que não há como sabê-lo, a priori (por exemplo, o aniversário da mãe), mas que, possivelmente, repetem-se a cada ano.

Pode-se também considerar, particularmente em casos como e-commerce, “dinâmicas de curta duração iniciadas pelo produto”, que também duram dias e que aparecem na vida das pessoas quando um determinado produto, adquirido (ou buscado) no passado, está próximo da data de sua substituição. Os telefones celulares, por exemplo, são substituídos a cada ano, por conta dos planos das operadoras de telefonia, que favorecem esta substituição para fidelização de clientes. Assim, para maior probabilidade de aceitação, pode-se sugerir-los depois deste tempo. Tal dinâmica também pode ser importante no lançamento de um determinado produto: o lançamento de um novo modelo de telefone celular fortemente divulgado pela mídia pode também sugerir sua inclusão como recomendação, por certo tempo.

Deve-se ainda destacar que, tipicamente, uma pessoa apresenta perfis de consumo distintos, simultaneamente: o “estudante universitário de Computação” pode, ao mesmo tempo, ser um “biker ativo”, ter grande interesse por filmes e música, etc.

Esta discussão, embora simplista, permite demonstrar os principais aspectos de um dos possíveis modos de incluir-se adaptabilidade (no conceito anteriormente definido) no contexto dos Sistemas de Recomendação e Navegação: um modelo em que os diferentes perfis de consumidor são simultaneamente considerados, ao mesmo tempo, utilizando-se da adaptabilidade para examinar o passado (ou parte deste) para a determinação de uma recomendação.

A Fig.2 mostra uma proposta de aplicação do conceito de adaptabilidade a Sistemas de Recomendação e Navegação para e-commerce, ilustrando a MMA (Máquina de Markov Adaptativa) para recomendação.

Na Fig.2, tem-se cada estado contendo um produto (ou categoria), além de outros, correlacionados. O produto principal está indicado pelo retângulo escuro e corresponde a algum produto já buscado (ou comprado) anteriormente pelo indivíduo. Os produtos correlacionados podem ser determinados por análise funcional (como na figura, em que tem-se produtos correlacionados por este critério) ou por

análise estatística como a correlação de Pearson, como realizado em [12].




Figura 2. MMA para recomendação

A recomendação é realizada pela transição de estados; pode-se ter a indicação do produto principal ou de um (ou mais) dos produtos correlacionados, a cada recomendação.

A dinâmica de adaptabilidade pode seguir o algoritmo da Fig.3, executado antes da transição da MMA.

```

Se houve a navegação para outro produto
{
    1.Incluir estado relativo ao produto na MMA
    2.Recalcular as probabilidades
}
Se é uma época notável geral (como Dia das Mães) E
ainda não foram incluídos os produtos adequados
{
    1.Incluir estado relativo aos produtos
    adequados à época notável
    2.Recalcular as probabilidades
}
Se é uma época notável individual
(come aniversário da mãe) E
ainda não foram incluídos os produtos adequados
{
    1.Incluir estado relativo aos produtos
    adequados à época notável
    2.Recalcular as probabilidades
}
Se passou-se mais de uma semana desde
o último cálculo de probabilidades
{
    Recalcular as probabilidades
}

```

Figura 3. Adaptação da MMA

Possivelmente, a detecção de datas notáveis pode ser realizada através de técnicas de identificação de sazonalidade, como ARIMA [14] ou outras, como [13], caracterizando-se alterações fortes de comportamento em determinadas épocas do ano, analisadas em horizontes relativamente longos como 10 anos.

O algoritmo descrito pode ser totalmente executado *client-side*, a partir de informações trazidas do servidor que incluem, basicamente, o registro dos acessos do indivíduo ao sistema, bem com da MMA. Como este conjunto de informações é relativamente reduzido, não há sobrecarga na rede.

V. CONCLUSÃO

A adaptabilidade não vem sendo propriamente considerada no contexto de Sistemas de Recomendação e de Navegação e sua inclusão pode trazer resultados positivos. O artigo apresentou uma das várias possíveis maneiras de considerá-la. Os modelos apresentados, embora parciais, sugerem que a abordagem proposta possa complementar as técnicas normalmente utilizadas nesta categoria de sistemas. Entretanto, a comprovação prática da melhoria que podem introduzir não foi realizada, devendo-se fazê-la em futuro próximo.

AGRADECIMENTOS

Os autores agradecem à Buscapé pelo patrocínio e apoio à realização deste trabalho, através do projeto FDTE-1176.

REFERÊNCIAS

- [1] Neto, J. J. “Contribuições à Metodologia de Construção de Compiladores”, Tese de Livre Docência, São Paulo, Escola Politécnica da USP, 1993.
- [2] Basseto, B. A. “Um sistema de composição musical automatizada, baseado em gramáticas sensíveis ao contexto, implementado com formalismos adaptativos”. Dissertação de Mestrado. Escola Politécnica da Universidade de São Paulo, 2000.
- [3] Shadbolt, N.; Hall, W.; Berners-Lee, T. “The Semantic Web Revisited”. IEEE Intelligent Systems, 2004.
- [4] Ziegler, C. “Semantic web recommender systems”. Lecture Note in Computer Science vol.3268 pp.78-89, 2004.
- [5] Herlocker, J.L.; Kostan, J.A.; Terveen, L.G.; Riedl, J.T. “Evaluating collaborative filtering recommender systems”. ACM Transactions on Information Systems, vol.22 no.1, 2004.
- [6] Exame. “Como Google e Facebook filtram a Internet”. http://exame.abril.com.br/tecnologia/noticias/como-google-e-facebook-filtram-a-internet?page=1&slug_name=como-google-e-facebook-filtram-a-internet. Acessado em 10 de outubro de 2011.
- [7] Ricci, F.; Rokach, L.; Shapira, B.; Kantor, P.B. “Recommender Systems Handbook”. Springer, 2011.
- [8] Xiaoyuan, S.; Khoshgoftaar, T. M. “A survey of collaborative filtering techniques”. Advances in Artificial Intelligence, vol.2009, 2009.
- [9] Pellegrini, W.; Wainer, J. “Processos de decisão de Markov”. RITA vol.XIV no.2, 2007.
- [10] Shani, G.; Heckerman, D.; Brafman, R.I. “AnMDP-based recommender system,” Journal of Machine Learning Research, vol. 6, pp. 1265–1295, 2005.
- [11] Alfenas, D.A.; Shibata, D.P.; Neto, J.J.; Pereira-Barretto, M.R. “Sistemas de Markov Adaptativos: formulação e plataforma de desenvolvimento”. Submetido ao WTA2012.
- [12] Segaran, T. “Programming collective intelligence”. O’Reilly, 2007.
- [13] Thio, N.; Karunasekera, S. “Medium-term client-perceived performance prediction”. Journal of Emerging Technologies in Web Intelligence, vol.2 no.1, 2010.
- [14] Brockwell, P.J.; Davis, A.D. “Introduction to time series and forecasting”. Springer, 1996.

Engenharia Mecatrônica) desde 2007, tendo ingressado na Escola Politécnica em 1990. Possui graduação em Engenharia Elétrica Modalidade Eletrônica pela Universidade de São Paulo (1989), mestrado em Engenharia pela Universidade de São Paulo (1991), Phd pela Carnegie Mellon University (1997), Livre-docência pela Universidade de São Paulo (2003). Atualmente é membro da comissão de inteligência artificial da SBC, membro do comitê editorial do Int. Journal on Approximate Reasoning. Pesquisas focam na automação de processos de decisão sob incerteza, incluindo representação de conhecimento e aprendizado (tópicos: inteligência artificial, redes bayesianas, conjuntos de probabilidade, modelos estatísticos gráficos)..



Willian Jean Fuks é graduado pela escola Politécnica da USP em Engenharia Elétrica com ênfase em Controle e Automação. Atualmente cursa o programa de Mestrado pelo departamento de Engenharia Mecânica da USP realizando pesquisas na área de aprendizagem de máquina e inteligência artificial para processos de decisão em lojas e-commerce.



Marcos Ribeiro Pereira-Barretto é graduado em Engenharia Elétrica (1983), mestre em Engenharia Elétrica (1988) e doutor em Engenharia Mecânica (1993) pela Escola Politécnica da Universidade de São Paulo. É professor da Escola Politécnica da USP desde 1986. Atua nas seguintes áreas de pesquisa: robôs sociais, computação afetiva e arquitetura de sistemas para aplicações críticas como Automação Industrial.



Fabio Gagliardi Cozman é Professor Titular da Escola Politécnica da Universidade de São Paulo (Dept.