

Aplicando Traços de Personalidade e Contextos em Sistemas de Recomendação para TV Digital: um facilitador do processo de ensino-aprendizagem

Luiz Felipe Trevisan¹, Silvio Cesar Cazella¹, Maria Augusta S. N. Nunes²

¹Universidade do Vale do Rio dos Sinos (UNISINOS)-São Leopoldo – RS – Brazil

²Universidade Federal de Sergipe (UFS)São Cristóvão – SE – Brasil.

trevisan@gmail.com, cazella@unisinós.br, gutanunes@dcomp.ufs.br

***Abstract.** This paper describes a model that applies personality traits in Recommendation Systems based on contexts focused in Digital TV (DTV). This model aims to minimize the overload information problem from the vast amount of content provided by DTV. For analysis of the proposed model was developed a DTV prototype, which through experimentation with real users showed a real gain. The results obtained are promising showing superior performance using personality traits in recommendation systems compared with the classical solution, demonstrating the possibility of its use in the teaching-learning process.*

***Resumo.** Este artigo descreve um modelo que aplica traços de personalidade em Sistemas de Recomendação com base em contextos focado em TV Digital (TVD). Este modelo visa minimizar o problema de sobrecarga de informação trazido pela vasta quantidade de conteúdo fornecido pela TVD. Para análise do modelo proposto foi desenvolvido um protótipo para TVD, que através de experimentação com amostra real de usuários mostrou ganho real. Os resultados obtidos apresentam-se promissores mostrando desempenho superior na inclusão de traços de personalidade em sistemas de recomendação comparado com a solução clássica, demonstrando desta forma a possibilidade de seu uso no processo de ensino-aprendizagem.*

1. Introdução

A TVD trouxe inúmeros benefícios para o telespectador, tais como a possibilidade do aumento da oferta de conteúdo, a possibilidade de novos serviços, a melhor qualidade de imagem e som, e a possibilidade de criação de conteúdo privilegiando as atividades de ensino já realizadas pela Internet. Contudo, este ensino baseado em televisão, conhecido como *T-learning* [Dias, Rodrigues e Junior 2010], poderia estar disponível a milhões de pessoas que atualmente não possuem acesso à internet. Juntamente com estes novos conteúdos oferecidos, aumenta também a dificuldade dos usuários/alunos encontrarem algo de acordo com suas preferências e reais necessidades.

Os Sistemas de Recomendação surgem como uma solução capaz de identificar os itens que possam ser do interesse do usuário sem que para isto ele precise navegar à procura do seu programa predileto e em situações no qual o usuário necessita fazer

escolhas sem um grande conhecimento de todas as possibilidades que lhe são apresentadas.

A maioria dos atuais Sistemas de Recomendação baseia-se exclusivamente nas variáveis usuário e item, comparando o conteúdo dos itens às preferências dos usuários (filtragem baseada em conteúdo) ou utilizando as avaliações realizadas pelos usuários aos itens e comparando com as de outros usuários (filtragem colaborativa).

Porém, em vários domínios, por exemplo, recomendar um pacote de férias, um conteúdo personalizado em um site Web, produtos em uma loja on-line, um filme ou, ainda, um objeto de aprendizagem ou mesmo um programa educacional é interessante a incorporação de informação contextual no processo de recomendação, aumentando as possibilidades de definir o momento mais adequado para recomendar certo item, e principalmente, quais itens podem interessar ao considerar o perfil do usuário em determinado contexto.

Atualmente, os Sistemas de Recomendação utilizam mais de uma técnica de recomendação conjugada para prevenir problemas clássicos de “*cold start*” entre outros. Nesse sentido, pesquisadores como González [González 2007] expandem o modelo já proposto por Burke [Burke 2002] de filtragem híbrida (conjugada) e propõe a inclusão da filtragem baseada em outros contextos, trabalhando com aspectos psicológicos, como a Inteligência Emocional e a Interação Social. Logo após, Nunes [Nunes 2008], por sua vez, expande o modelo de González, utilizando a personalidade do usuário como um contexto interessante a fim de aperfeiçoar as recomendações geradas para o mesmo.

Este artigo foca a aplicação de traços de personalidade e informações contextuais em Sistemas de Recomendação no contexto de programas televisivos. Alguns trabalhos relacionados e focados em educação e TVD foram propostos por Aarreniemi-Jokipelto [Aarreniemi-Jokipelto 2005] e por Matos, Julião e Santos no seu estudo sobre TVD e Educação a Distância [Matos, Julião e Santos 2007]. Porém, ambos os trabalhos não apresentam preocupação com a sobrecarga de informação a que o usuário/estudante poderia ser exposto e nem aos seus traços de personalidade. Hendrik, Hummel e Kope [Hendrik, Hummel e Kope 2008] apresentam importantes considerações sobre a importância do uso de Sistemas de Recomendação no ensino-aprendizado, focando na educação continuada do usuário/estudante.

Desta forma a contribuição do trabalho aqui apresentado recai na proposta de um modelo que aplica traços de personalidade em Sistemas de Recomendação com base em contextos focado em TVD podendo ser aplicado como solução no processo de ensino-aprendizagem, uma vez que considera questões específicas referentes a traços de personalidade do usuário/aluno. Estas informações adicionais sobre o usuário são incorporadas à abordagem tradicional de filtragem colaborativa. O modelo proposto foi prototipado e registrado no INPI, sendo avaliado utilizando duas métricas amplamente difundidas na literatura: MAE e precisão [Cazella et al. 2009].

O restante deste artigo está organizado em sete seções. Nas próximas duas seções, serão apresentados os conceitos relacionados a Sistemas de Recomendação e *T-learning*. Após, a seção 4 apresenta o modelo de recomendação proposto neste trabalho. Já nas seções 5 e 6, serão abordados o protótipo desenvolvido e os experimentos realizados. Finalmente, a seção 7 discutirá os resultados obtidos pelo trabalho.

2. Sistemas de Recomendação

Muitas vezes é necessário fazer escolhas sem um grande conhecimento das possibilidades que nos são apresentadas [Resnick e Varian 1997]. Normalmente nos baseamos nas recomendações de amigos, através de opiniões de especialistas, ou ainda, a partir de outras fontes. Os Sistemas de Recomendação ajudam e aumentam este processo social natural já existente entre as pessoas. Porém para recomendar produtos, serviços ou qualquer outro tipo de item, é necessário aprender sobre o usuário do sistema.

Um Sistema de Recomendação típico agrega e direciona as avaliações de itens feitas pelos usuários e as disponibiliza como recomendações para os indivíduos considerados potencialmente interessados neste tipo de recomendação [Resnick e Varian 1997]. O grande desafio está em descobrir o relacionamento de interesses entre os usuários, realizando desta forma o correto casamento entre os itens que estão sendo avaliados e os usuários que estão recebendo a referida recomendação.

A essência dos sistemas colaborativos está na troca de experiências entre as pessoas que possuem interesses comuns [Nunes e Cazella 2011]. Para tanto, ao invés do conteúdo dos itens, esta filtragem é baseada nas avaliações feitas pelos usuários aos itens. A filtragem colaborativa foi proposta para suprir as necessidades da filtragem baseada em conteúdo [Herlocker 2000]. Desta forma, os usuários receberão recomendações de pessoas com gostos similares e que gostaram do item no passado, enquanto que na filtragem baseada em conteúdo serão recomendados itens similares aos quais o usuário gostou no passado. É um processo que busca usuários similares e calcula, baseado na semelhança entre os mesmos, qual a nota aproximada que o usuário em questão daria ao item caso o fizesse.

3. *T-learning*

T-learning é uma técnica já bastante utilizada no ensino à distância (EAD), promovendo ensino para uma larga população, pois o aparelho televisor está presente em quase todos os lares [Dias, Rodrigues e Junior 2010]. A interatividade provida pela TVD pode levar a EAD a outro patamar, levando a regiões antes isoladas conteúdos atualmente só disponíveis em algumas regiões ou em grandes escolas e universidades [Matos, Julião e Santos 2007].

O projeto do Sistema Brasileiro de Televisão Digital (SBTVD) foi instituído pelo Decreto Presidencial nº 4.901, de 26 de novembro de 2003 e baseia-se no padrão da TVD japonesa, com algumas modificações na camada de compressão e middleware. O Brasil optou pela criação do seu próprio middleware, denominado Ginga, resultado da junção dos middlewares FlexTV e MAESTRO desenvolvidos por consórcios liderados pela UFPB e pela PUC-RJ respectivamente [Mendes 2007].

A interatividade propiciada pela TVD oferece incontáveis oportunidades de melhoria da TV tradicional [Freed 2011]. Destaca-se entre seus objetivos as ações de promover a inclusão social, a diversidade cultural do País e a língua pátria por meio do acesso à tecnologia digital, visando à democratização da informação; e propiciar a criação de rede universal de educação à distância.

Esta nova mídia traz a interação que nos programas de ensino consagradamente reconhecidos, somente se realizava por meios (telefone, correios, fax, internet) que

careciam de agilidade e atratividade [Dias, Rodrigues e Junior 2010]. Esta interação (bidimensional) possibilitaria envio de provas, dúvidas, trabalhos, votações e até comunicação instantânea entre aluno-professor e aluno-aluno [Matos, Julião e Santos 2007], utilizando um canal de retorno disponível através de qualquer tecnologia de rede de acesso.

4. Modelo do TvPlus

O modelo proposto por este trabalho servirá de base para a construção de Sistemas de Recomendação para conteúdo televisivo, utilizando informações contextuais e a personalidade do usuário. A personalidade auxilia na busca de usuários similares e as informações contextuais auxiliam a recuperar programas que mais se adaptem ao contexto no qual o usuário está inserido. Desta forma, em um contexto de educação seriam recomendados os programas da TVD que mais atendessem as necessidades do aluno considerando traços da sua personalidade como guia nesse processo.

Utilizando um perfil mais rico do usuário com a agregação dos seus traços de personalidade, o cálculo de similaridade entre usuários inclui estas informações no processo de filtragem colaborativa. Desta forma, este processo seleciona a vizinhança que possui as avaliações mais similares ao usuário alvo (modelo tradicional) e também as que mais se aproximam pelos traços de personalidade (Figura 1).

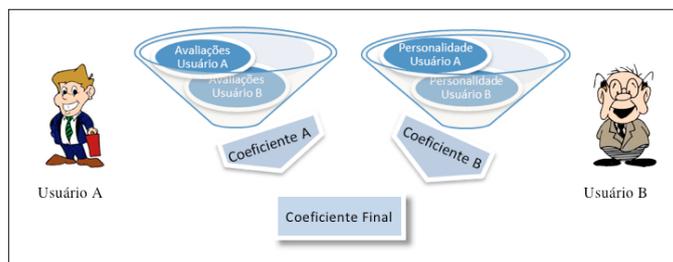


Figura 1 – Esquema do cálculo de similaridade

A personalidade é relativamente estável, permanecendo assim por aproximadamente 45 anos [Soldz e Vaillant 1998]. Os traços de personalidade descrevem as diferenças psicológicas entre indivíduos e podem ser computacionalmente modelados e codificados [Nunes 2008]. Percebendo que alguns fatores sempre se repetiam, psicólogos criaram o *Big Five* ou Modelo dos Cinco Grandes Fatores. Pesquisadores propuseram um grande número de questionários baseados no *Big Five*, e segundo o estudo de Nunes [Nunes 2008], os dois melhores avaliados estão descritos no Quadro 1.

Quadro 1. Questionários para mapeamento de traços de personalidade

NEO-IPIP	Composto de 300 questões.
	Gratuito.
	Baseado no NEO-PI-R (mais robusto, utilizado e bem avaliado inventário comercial)
	Mapeia as seis facetas de cada um dos cinco fatores do Big Five.
TIPI	Composto de 10 questões.
	Gratuito.
	Rápido de responder.
	Mapeia somente os cinco fatores do Big Five.

A técnica baseada em personalidade geralmente é aplicada juntamente com outra técnica [Cazella, Nunes e Reategui 2010], como a filtragem colaborativa e/ou baseada em conteúdo, constituindo-se numa técnica de recomendação híbrida [Burke 2002].

Como estes traços podem ser obtidos a partir da aplicação de testes de personalidade, foram escolhidos o NEO-IPIP e o TIPI por ambos serem gratuitos e apresentarem resultados positivos em testes realizados por Nunes [Nunes 2008]. Os contextos disponíveis para o usuário são definidos a priori e compostos por uma lista de gêneros, subgêneros e classificações etárias.

Após a execução do processo de recomendação, utilizando a filtragem colaborativa, e obtenção de uma lista de programas recomendáveis ao usuário, foi utilizada uma pós-filtragem, onde as informações contextuais obtidas do usuário foram utilizadas. A pós-filtragem foi utilizada, pois permite a utilização da técnica de filtragem colaborativa e minimiza problemas em bases de dados com grande esparsidade. A possibilidade da utilização da filtragem colaborativa nesta técnica de pós-filtragem foi imprescindível para o uso dos traços de personalidade, descritos anteriormente, juntamente, com as informações contextuais.

O ajuste na fase de pós-filtragem realizado na nota predita foi definido empiricamente a partir de alguns testes realizados, como por exemplo: Se o contexto do usuário possui o gênero do programa a ser avaliado, a nota predita é acrescida de 30% e em caso contrário, decrescida de 30%. Algo similar ocorre com a classificação etária. Caso o contexto possua esta classificação cadastrada, a nota é acrescida de 20% e se não, decrescida de 40%. As avaliações realizadas pelos usuários de itens da base de dados são definidas utilizando a escala Likert de cinco pontos. As recomendações geradas também usam escala Likert de cinco pontos e somente devem ser dirigidas aos usuários caso a nota predita seja igual ou superior a três.

5. Protótipo

Uma aplicação para recomendação de programas de TV pode ser utilizada em diferentes aparelhos eletrônicos: celulares, computadores e televisores, entre outros com algum tipo de acesso a rede mundial de computadores. Porém, o mais usual é disponibilizar este tipo de aplicação em um aparelho de televisão. O surgimento da TVD no Brasil, a crescente expansão do sinal digital e a possibilidade do desenvolvimento de programas interativos tornou possível a criação deste tipo de sistema proposto por este trabalho. Então, utilizando o SBTV, foram testadas as duas plataformas do Ginga (Ginga NCL e Ginga-J) para o desenvolvimento do protótipo da aplicação.

O protótipo em TVD acessa um servidor HTTP e busca as recomendações disponíveis para o usuário que o está utilizando. O telespectador pode identificar o quanto o programa recomendado atende às suas necessidades ou desejos. Esta informação alimenta o sistema como uma nova avaliação, aumentando a precisão de futuras sugestões. O contexto cujo usuário está inserido no momento da recomendação é informado pelo mesmo de forma explícita a partir de uma lista pré-definida, porém configurável. Estes contextos foram elencados empiricamente a partir da análise dos gêneros, subgêneros e classificação etária dos programas disponíveis na grade de programação. Os testes de personalidade foram realizados utilizando a aplicação *Personality Inventory* [Nunes et al. 2010]. Esta é uma aplicação online que aplica os testes NEO-IPIP e TIPI. Cada questão respondida tem um valor atribuído entre 1 e 5. A

partir destes valores, é realizado um cálculo que gera um valor entre 1 e 100 para cada um dos itens do Big Five.

A lista de itens recomendados apresenta: o título do programa, o ícone do canal, a classificação etária e a avaliação dada pelo usuário (representada pelas estrelas ao lado de cada programa) (Figura 2).

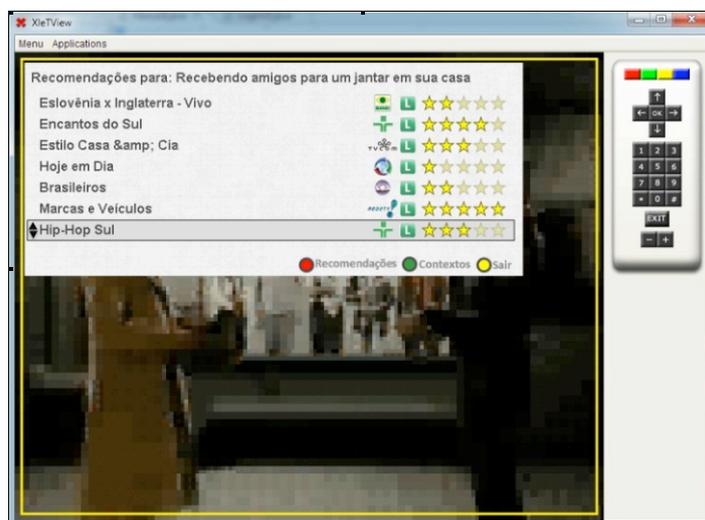


Figura 2 – Lista de recomendações fornecidas pelo protótipo

Cada avaliação realizada pelo usuário pela TV é enviada para o servidor e armazenada na tabela de avaliações. Quando o algoritmo de recomendação for executado novamente por qualquer usuário do sistema, estas informações transmitidas no *feedback* realizado serão processadas e poderão gerar uma recomendação diferente das anteriormente criadas

6. Experimento

A fim de avaliar o modelo desenvolvido, foi criada uma aplicação web para a simulação de um ambiente de interação com a TVD, tornando viável a realização do experimento com uma população maior. Para a realização deste experimento, optou-se pela utilização de uma amostra por conveniência de dezoito estudantes dos cursos de Informática da Universidade do Vale do Rio dos Sinos e Universidade Federal de Sergipe.

Os estudantes utilizaram o sistema a fim de receber duas listas de recomendações. A primeira criada utilizando a abordagem tradicional de filtragem colaborativa. Já a segunda utilizando também o peso da nota a partir do perfil do usuário, avaliando o contexto e os traços de personalidade. Para cada item, os usuários avaliaram se a recomendação estava de acordo com as suas preferências. Foram realizadas três etapas: 1º) Os usuários foram convidados a avaliarem uma amostra de programas de TV selecionados de forma randômica; 2º) os usuários receberam recomendações pelo modelo clássico, ou seja, sem a utilização do resultado da análise de personalidade, e foram convidados a fornecer um *feedback*; 3º) os usuários receberam recomendações pelo modelo com a utilização do resultado da análise de personalidade, e foram convidados a fornecer um *feedback*.

7. Resultados

Foram recomendados 519 programas durante o experimento, e houve o *feedback* por parte dos amostrados em 423 destas recomendações. Deste total, 145 recomendações foram geradas utilizando a solução clássica de filtragem colaborativa, 346 recomendações foram geradas com base no modelo proposto por este trabalho e 28 utilizando filtragem baseada em conteúdo. Estes 28 itens foram recomendados para os primeiros participantes do experimento, pois como a esparsialidade ainda era alta na base de dados, não havia itens suficientes para apresentar aos usuários.

Visando analisar o ganho proporcionado pelo modelo proposto, a primeira métrica utilizada foi o Erro Absoluto Médio (*Mean Absolute Error* - MAE) que calcula a média do desvio entre a nota predita pelo sistema para um determinado item e a nota real fornecida pelo usuário ao mesmo item [Herlocker 2004]. Quando mais próximo de zero for o resultado, supõe-se que melhor é o sistema de recomendação. Também foi aplicada a métrica de precisão. Esta métrica verifica o percentual de itens considerados relevantes pelo usuário [Herlocker 2004], sendo que resultados próximos do valor 1 indicam bons Sistemas de Recomendação.

Os resultados obtidos evidenciam que a assertividade do protótipo utilizando o modelo proposto neste trabalho apresentou melhor desempenho que a solução clássica tradicional utilizada em Sistemas de Recomendação, os quais são desenvolvidos empregando a técnica de filtragem colaborativa. O MAE apresentou-se 8.5% menor e a precisão 5.7% maior com a aplicação do modelo, do que na solução clássica.

8. Conclusão e perspectivas

Este trabalho propôs um modelo de Sistema de Recomendação de programas de televisão, intitulado TvPlus, que visa, principalmente, resolver o problema de sobrecarga otimizando o resultado das recomendações clássicas através do uso inovador de traços de personalidade. Optou-se pela TVD por conta da interatividade e alcance provido por esta nova mídia. A utilização de traços de personalidade e informação contextual surgiu com a proposta objetivando potencializar personalização efetiva de programas para o público de TVD. Os resultados obtidos mostram-se interessantes para a área de Sistemas de Recomendação de forma geral, como também para o desenvolvimento de futuros sistemas.

Acredita-se que o protótipo do TV Plus, após pequenos ajustes, possa ser usado como complemento à Educação presencial formal (Ensino fundamental e médio, por exemplo) principalmente da comunidade carente brasileira, bem como a proposta se estende para a Educação a distância via TVD (com ou sem a utilização da *web*).

8.1. Questões para discussão

Em países de dimensão continental, como no Brasil, muitas vezes o acesso à educação em pontos isolados do mapa é bastante limitado. Infelizmente, esse ainda é um cenário real para a comunidade brasileira. Nesses casos, o acesso à educação é inviabilizado muitas vezes pelo difícil acesso à sala de aula por parte dos alunos, bem como, muitas vezes a falta de fomento governamental que inviabiliza uma estrutura mínima que possibilite o ensino além das series elementares do ensino básico. Considerando esse aspecto:

- Como efetivamente a TV (convencional ou digital) está inserida nesse contexto educacional hoje?
- De que forma e com que objetivos pedagógicos está sendo utilizada?
- Atualmente já se aplica esse tipo de recurso (personalização de ensino pela mídia) para esse tipo de público?
- Que efeito uma suposta personalização desse tipo de mídia causaria na qualidade do ensino à massa estudantil de baixa renda e com difícil acesso à sala de aula? (o cenário é que a educação a distancia via TVD não deva ser uma proposta de sobreposição ao ensino formal tradicional, mas sim uma ferramenta a mais de motivação e complementação de aprendizagem.)
- Há programas educacionais suficientes que permitam essa personalização no ensino atualmente? Ou, qual seria o novo cenário que deveria ser fomentado via governo para que efetivamente se pudesse utilizar a TVD como um alicerce fortificador e motivador no processo de ensino aprendizagem atualmente, principalmente das comunidades carentes?

Referências

- Aarreniemi-Jokipielto, Päivi. (2005) "T-learning Model for Learning via Digital TV". In Proceedings of Annual Conference on Innovation in Education for Electrical and Information Engineering, Lappeenranta, Finland.
- Adomavicius, Gediminas e Tuzhilin, Alexander. (2005) "Toward the Next Generation of Recommender Systems: A Survey of the State-of-the-Art and Possible Extensions". In: IEEE Transactions on Knowledge and Data Engineering, Los Alamitos, p. 734-749.
- Burke, Robin. (2002) "Hybrid Recommender Systems: Survey and Experiments". In: User Modeling and User-Adapted Interaction, Hingham, p. 331-370.
- Cazella, Sílvia C.; Nunes, Maria A. S. N.; Reategui, Eliseo B. (2010) "A Ciência do Palpite: Estado da Arte em Sistemas de Recomendação". In: Jornada de Atualização de Informática – JAI 2010 – CSBC. Rio de Janeiro: PUC RIO, v. 1, p. 161-216.
- Cazella, Sílvia C.; Reategui, Eliseo Bern; Machado, Munique; Barbosa Jorge Luis V. (2009) "Recomendação de Objetos de Aprendizagem Empregando Filtragem Colaborativa e Competências". In: Simpósio Brasileiro de Informática na Educação, Florianópolis.
- Dias, Flávio R.; Rodrigues, Ariádnés e Junior, Ivaldir H. de F. (2010) "Estudo de Caso: EAD Através da TV Digital Interativa com o Software Trânsito Legal". In: Revista Novas Tecnologias na Educação, Porto Alegre, v. 8, n. 1.
- Drachsler, Hendrik; Hummel, Hans G. K.; Kope, Rob. (2008) "Personal recommender systems for learners in lifelong learning networks: the requirements, techniques and model". In: International Journal of Learning Technology, v. 3, n. 4.
- Freed, Ken. (2011) "Desenvolvimento de Aplicações para TV Digital Interativa", <http://www.media-visions.com/itv-newbies.html>, Maio.
- Herlocker, Jonathan L. (2000) "Understanding and Improving Automated Collaborative Filtering Systems". Tese. Universidade de Minnesota, Minnesota.
- Matos, Felipe S. de; Julião, Wilhelm S. e Santos, Neide. (2007) "TV Digital e Educação a Distância: Discutindo Alguns Pontos e Propondo um Protótipo de Sistema". In: XVIII Simpósio Brasileiro de Informática na Educação – SBIE, Mackenzie, p. 569-578.
- Nunes, Maria A. S. N. (2008) "Recommender Systems based on Personality Traits". Tese. Universidade Montpellier 2, Montpellier.
- Nunes, Maria A. S. N. et al. (2010) "Computação Afetiva e sua influência na personalização de Ambientes Educacionais: gerando equipes compatíveis para uso em AVAs na EaD." In: Glaucio José Couri Machado. (Org.). Educação e Ciberespaço: Estudos, propostas e desafios. Aracaju: Virtus Editora, v. 1, p. 308-347.
- Nunes, M. A. S. N.; Cazella, S. C. (2011) "O que sua Personalidade revela? Fidelizando clientes web através de Sistemas de Recomendação e Traços de Personalidade". In: Patricia Vilain e Valter Roesler. (Org.). Tópicos em Banco de Dados e Multimídia e Web. Porto Alegre: SBC, v. 1, p. 91-122.
- Resnick, Paul e Varian, Hal R. (1997) "Recommender Systems". In: Communications of the ACM, Nova Iorque, p. 56-58.
- Smyth, Barry e Cotter, Paul. (2001) "Personalized Electronic Program Guides for Digital TV". In: AI Magazine, Menlo Park, p. 89-98.
- Soldz, Stephen e Vaillant, George E. (1999) "The big five personality traits and the life course: A 45 years longitudinal study". Journal of Research in Personality, v. 33, n. 2, p. 208-232.