

Capítulo

4

O que sua personalidade revela?

Fidelizando clientes web através de Sistemas de Recomendação e traços de personalidade

Maria Augusta S. N. Nunes¹, Silvio César Cazella²

¹Universidade Federal de Sergipe {gutanunes@dcomp.ufs.com}

²UFCSPA/UNISINOS{silvio.cazella@gmail.com}

Abstract

Recently, studies from (Damásio 1994), (Simon 1983), (Picard 1997), (Trappl et al 2003), (Thagard 2006) and (Nunes 2009) have demonstrated how important psychological aspects of people such as personality traits and emotions are during the human decision-making process. Those studies have demonstrated how much subtle and inherent aspects from human personality have influenced the human interpersonal interaction. Indeed it proved how much those aspects could enhance the personalization during the human-human interaction and how it could be beneficial by offering products to customers in conventional business processes in the real world. Some studies (Reeves and Nass 1996) have been conducted showing that humans respond psychologically to computers and other media as if these were also human. Considering this aspect, no matter what kind of resource the computer use, the computer will be potentially making decisions and working with and for people. Thus, some understanding of the nature of human psychological aspects by computer is extremely relevant and necessary in order to improve its understanding. By improving those aspects, the computer could also improve the level of customization and optimization of their processes of decision making in order to enhance human-computer interaction and therefore the personalization on the web.

Resumo

Estudos recentes de psicólogos, neurologistas, antropólogos e cientistas computacionais (Damásio 1994), (Simon 1983), (Picard 1997), (Trappl et al 2003), (Thagard 2006) e (Nunes 2009) têm provado o quão importante os aspectos psicológicos humanos, tais como emoção e traços de personalidade, são no processo de tomada de decisão humana. Os mesmos estudos provam que esses aspectos sutis e inerentes a personalidade humana influenciam de maneira efetiva e particular suas interações interpessoais potencializando a personalização na interação humano-humano podendo substancialmente favorecer aspectos de processos comerciais convencionais na oferta de produtos e serviços no mundo real. Alguns estudos (Reeves and Nass 1996) têm sido conduzidos indicando que os humanos respondem psicologicamente a computadores e outras mídias como se esses fossem, também, humanos. Considerando

esse aspecto, não importa que recurso o computador estará usando, entretanto, em todos os casos, o computador estará, potencialmente, tomando decisões e trabalhando com e para as pessoas. Assim, para o computador, o entendimento da natureza psicológica humana é extremamente relevante e necessária para que o mesmo possa melhorar sua compreensão do ser com quem interage, melhorando assim, o nível de personalização e otimização dos seus processos de tomada de decisão visando potencializar a interação humano-computador e conseqüentemente a personalização em ambientes web.

4.1. Introdução

Atualmente o uso da *web* como uma fonte de entretenimento, cultura, informação, de produtos e serviços é, de certa forma, indispensável às atividades diárias da grande parte das pessoas nas civilizações modernas. Atualmente a *web* é considerada pelas pessoas como uma fonte inesgotável de recursos, de todo tipo, onde tudo pode ser encontrado, executado, solucionado e, principalmente, onde tudo é possível e acessível. Nesse tipo de ambiente, onde os humanos podem virtualmente viver e usar qualquer recurso real/virtual para alcançar o desejado, a personalização das informações, produtos e serviços oferecidos aos usuários é fundamental. Não importa que tipo de recurso na *web* seja utilizado, em todos os casos o computador estará potencialmente trabalhando com, e, para as pessoas. Para que a personalização ocorra de forma adequada uma eficiente forma de realizar o processo de tomada de decisão computacional deve ser adotada.

Considerando a sobrecarga de informação disponibilizadas na *web* dificilmente a personalização de informações, produtos e serviços tem se dado de forma efetiva no Brasil. Na Europa e Estados Unidos esse problema tem sido contornado pelo uso efetivo de Sistemas de Recomendação que manipulam a grande massa de informação disponível na *web* filtrando o que realmente interessa ao usuário de *e-commerce* e *e-services*. Dessa forma, a *web* brasileira vem perdendo um grande potencial mercadológico pois o empresariado vem negligenciando esse aspecto. Há uma estranha contradição nessa questão, pois a Academia brasileira produz ciência e tecnologia suficiente para inovar as técnicas utilizadas em *e-commerce* e em *e-services* no Brasil, entretanto o conhecimento produzido é subutilizado pelo empresariado brasileiro, o que acaba acarretando o déficit de nossa tecnologia comercial se comparado a Europa e Estados Unidos.

Assim, esse capítulo propõe diminuir o déficit disponibilizando um portfólio dos trabalhos no que tange tanto o estado da arte como o da técnica dos trabalhos em andamento que direcionam a área de Sistemas de Recomendação com o uso inovador da personalidade, subárea da Computação Afetiva, principalmente na linha de *e-commerce* e *e-services*.

A seguir apresenta-se a estrutura do capítulo: na seção 1.1 é discutido aspectos introdutórios do assunto proposto pelo capítulo bem como sua agenda; na seção 1.2 é introduzida a área Computação Afetiva, incluindo uma breve descrição dos aspectos que envolvem a afetividade enfatizando a personalidade; na seção 1.3, é descrito e exemplificado como, porque e quando a Computação Afetiva, principalmente a personalidade, potencializa a tomada de decisão humana. Apresenta-se, então, as abordagens de personalidade existentes exemplificando as abordagens codificáveis em computadores. Na seqüência, discute-se como os aspectos de personalidade influenciam na identidade do usuário e como isso afeta seu perfil. Seguindo-se pela discussão dos critérios de armazenamento existentes (*Markup Languages, Ontologies, User Profile*). Finalmente, são descritas as metodologias existentes hoje para extração de personalidade por computadores; na quarta seção são descritas as formas existentes de tomada de decisão computacional enfatizando os Sistemas de Recomendação, focando em sua aplicação em *e-commerce, e-services* e TV digital. Questões relativas a técnicas, e estratégias de recomendação serão apresentadas com o resumo de seus algoritmos; a seção 1.5 apresenta a concatenação das duas seções anteriores. Nessa será exemplificado como Sistemas de Recomendação podem efetivamente personalizar ambientes com

ganhos efetivos usando a personalidade; finalmente a seção 1.6 apresentada conclusões e perspectivas futuras da área de pesquisa, seguido pela seção 1.7 onde as referências bibliográficas são apresentadas.

4.2. Computação Afetiva

Desde a década de 70, cientistas computacionais, principalmente da área de Computação Afetiva buscam modelar e implementar aspectos psicológicos humanos em ambientes computacionais.

Na Computação Afetiva estuda-se como os computadores podem reconhecer, modelar e responder às emoções humanas (dentre outros aspectos) e, dessa forma, como podem expressá-las através de uma interface/interação computacional (Picard 1997). Acredita-se que permitindo que computadores expressem/captem fisiológica e verbalmente informações psico-afetivas, em uma interação humano-computador, é possível induzir e despertar afetividade em humanos. O principal objetivo de se promover esse interfaceamento afetivo é contribuir para o aumento da coerência, consistência, predicabilidade e credibilidade das reações personalizando as respostas computacionais providas durante a interação humana via interface humano-computador.

O usuário é um agente em um ambiente computacional (*web*, por exemplo) onde a interface, ou a adaptação da mesma, é fundamental para que se crie uma personalização da interação com o usuário contextualizado-o em sua zona de conforto e necessidades emergentes. Muitas características da identidade pessoal (aspectos psicológicos e habilidades sociais) do usuário podem ser captadas por meio de símbolos disponíveis na interface dos ambientes computacionais. Porém cada símbolo pode ser interpretado diferentemente por cada sujeito/usuário, considerando como o mesmo os projeta durante suas interações com o mundo real. Da mesma forma, os símbolos projetados via interface são, também, interpretados diferentemente por cada usuário, emergindo/brotando, dessa forma, diferentes aspectos psicológicos, tais como personalidade, durante sua interação no ambiente podendo influenciar definitivamente (positiva ou negativamente) na interação do usuário em ambientes computacionais atuais, tais como *e-commerce* e *e-services*.

4.3. Tomada de decisão humana & Computação Afetiva

Como descrito anteriormente, estudos recentes de psicólogos, neurologistas, antropólogos e cientistas computacionais (Damásio 1994), (Simon 1983), (Goleman 1995), (Paiva 2000), (Picard 1997), (Trapp et al 2003), (Thagard 2006) e (Nunes 2009) têm provado o quão importante os aspectos psicológicos humanos, tais como Emoção e personalidade, são no processo de tomada de decisão humano influenciando, assim, suas interações. Assim, para o computador, o entendimento da natureza psicológica humana é extremamente relevante e necessária para que se possa melhorar seu nível de personalização e otimizar a interação também em ambientes computacionais. Considerando essa necessidade, esse capítulo se propõe a tratar a questão da personalidade humana como forma de potencializar a interação humano-computador apresentando primeiramente abordagens psicológicas passíveis de codificação em computadores.

4.3.1. Personalidade

Na Psicologia não existe um consenso para a definição de personalidade. De acordo com Schultz (1990) a origem em latim da palavra personalidade “*Persona*” refere-se a máscara usada por um ator para a encenação de uma peça teatral ao público. Schultz ainda estende sua definição descrevendo personalidade como “um conjunto permanente e exclusivo de características identificáveis nas ações/interações do indivíduo em diferentes situações”. Ainda, Burger (2000) define personalidade como “um padrão de comportamento consistente e processo intrapessoal que é originado internamente no indivíduo”.

A personalidade é mais que apenas a aparência superficial e física de um indivíduo, ela é relativamente estável e previsível, porém ela não é necessariamente rígida e imutável. A personalidade, geralmente, permanece estável por um período de 45 anos iniciando na fase adulta (Soldz and Vaillant 1998). A personalidade pode ser definida segundo diversas abordagens, uma abordagem bastante interessante é a abordagem de traços de personalidade que permite diferenciar psicologicamente pessoas usando traços mesuráveis e conceituáveis. Traços de personalidade são formados por um conjunto de características humanas factíveis de modelagem e implementação em computadores (Nunes 2009).

Os traços de personalidade foram historicamente definidos por Allport (1927). Allport criou 17.953 traços (“comuns” e “individuais”) para descrever a personalidade de um indivíduo. Logo após Allport, pesquisadores assumiram que todos os homens eram identificáveis “como algum outro homem” e, dessa forma, a maioria das diferenças individuais (representadas pelos traços individuais e Allport) eram insignificantes nas interações diárias humanas e, assim eles limitaram exponencialmente o número de definições de traços. Posteriormente, os pesquisadores reduziram mais de 99% dos traços. Acabaram restando cinco fatores que se replicaram em seus estudos empíricos, como resultado, o modelo *Big Five* (John and Srivastava 1999) foi criado. Porém, mesmo considerando que o *Big Five* representasse grande eficiência na representação da estrutura de personalidade, ele não garantia exaustivamente todas as dimensões de personalidade. Dessa forma, *facet*s também foram criadas e usadas pelos psicólogos para dotar o *Big Five* de características mais detalhadas (Goldberg *et al* 2006).

Para que exista possibilidade de se personalizar a oferta e recomendar produtos, serviços em um ambiente *web* à um usuário é necessário ter-se conhecimento sobre quem é este usuário. Antes mesmo de pensar em capturar e armazenar a informações pessoais e comportamentais dele é necessário identificar que o tipo de informação será relevante para a geração da personalização adequada. Para a correta geração da recomendação a definição do perfil do usuário e tipo de informações usada é imprescindível. Abaixo apresenta-se como a personalidade influencia nessas definições através de sua influência na identidade e, conseqüentemente no o perfil do usuário.

4.3.2. Identidade e Perfil de Usuário

4.3.2.1 Identidade do Usuário

Segundo a visão da psicologia clássica, identidade é definida pela autoconsciência/visão que cada pessoa possui de si mesma, enquanto que na Psicologia Social e Sociologia, identidade pode ser definida como a forma que cada pessoa é vista sob os olhos da sociedade.

Segundo os pesquisadores de Teoria da personalidade, o desenvolvimento da identidade recebe uma importante influência da personalidade. Boyd (Boyd 2002) descreve dois aspectos diferentes da identidade: a noção internalizada do “eu” (identidade interna) e a versão projetada da internalização do “eu” (identidade social). Nessa mesma linha, Erikson (1980) por exemplo, acredita que identidade (EGO) tem uma representação pessoal interna (identidade interna) bem como uma representação social (identidade social). Giddens (1991) concorda que sem experiências sociais o “eu” não pode internalizar evolução. Giddens ainda afirma que a identidade de um indivíduo não é estática, ela pode ser representada em constante evolução, principalmente porque o componente social é dinâmico e esta sempre sendo modificado. Mead (1934) ainda define “eu” e “mim”, onde “mim” representa o aspecto socializado da pessoa (identidade social), enquanto que o “eu” representa como a pessoa se define em relação aos outras pessoas da sociedade (identidade individual).

Note que no mundo virtual onde não há presença física e conseqüentemente não há percepção de características sutis da identidade, várias pistas que possivelmente identificariam dicas de preferências, comportamentos, habilidades sociais, entre outras, são ausentes, ao contrário do que ocorre no mundo real (Donath 1999). Donath (2000) afirma que conhecer a identidade da pessoa é vital para uma adequada personalização de uma ambiente no mundo virtual, como na *web* por exemplo. Goffman (1959) afirma ainda, que as pessoas se esforçam para se apresentar como “aceitáveis” aos olhos da sociedade (em comunidades virtuais, por exemplo).

Considerando a identidade como um canal importante onde as características objetivas e subjetivas das pessoas emergem, denomina-se de fundamental importância seu uso em Sistemas de Recomendação no intuito de fornecer pistas sobre os futuros comportamentos e necessidades dos usuários em um dado ambiente onde a personalização se faz eficaz.

T tecnicamente, em Ciência da Computação, a tecnologia usada para formalizar a identidade em um dado ambiente computacional é pelo uso de Perfil/Modelo do Usuário (identidade Interna) e Reputação do Usuário (identidade Social).

4.3.2.2 Perfil de Usuário

Donath (1999) afirma que para a formação eficiente de uma identidade Virtual é crucial que o usuário tenha definida sua identidade interna e sua identidade social. No mundo virtual a identidade interna do usuário é definida por ele próprio similar ao mundo real (algumas vezes também é descoberta através de técnicas de *Machine Learning*). Enquanto a identidade social é definida pelos outros membros do mundo virtual (elucidada na próxima seção). Tanto a identidade interna, como a identidade social são armazenadas no perfil do usuário.

Perfis de usuários são conceitos aproximados, eles refletem o interesse do usuário com relação a vários assuntos em um momento particular. Cada termo que um perfil de usuário expressa é, num certo grau, características de um usuário particular (Poo et al 2003) incluindo todas as informações diretamente solicitadas a ele e aprendidas implicitamente durante sua interação na *web* (Carreira et al 2004). Fisicamente, o perfil do usuário pode ser visto como uma base de dados onde a informação sobre o usuário, incluindo seus interesses e preferências, é armazenada e pode ser dinamicamente mantido (Rousseau et al. 2004), (Poo et al. 2003).

Na *web* encontram-se muitos tipos de perfis de usuário com diferentes graus de complexidade. Eles são desenvolvidos no contexto de *e-commerce*, *e-learning* e *e-community*, por exemplo. Kobsa (2007) cria uma modelagem genérica de usuário para ser usada como uma *shell* para a criação de categorias de informação sobre o usuário objetivando personalizar as aplicações *web*. O modelo proposto por Kobsa é um dos mais reputados. Paiva e Self (1995) também desenvolveram uma *shell* de modelo de usuário chamado *TAGUS*, criado para melhor modelar os alunos para atividades de aprendizado. No *e-commerce*, (Riedl et al. 1999), (Herlocker et al. 2004), (Konstan et al. 1997), (Schafer et al. 1999) e (Schafer et al. 2001), do GroupLens, criaram vários modelos de usuário baseado em ranqueamento de filmes, de notícias, entre outros. Esses modelos têm sido usados nos Sistemas de Recomendação criados pelo GroupLens.

Considerando ainda definições de modelo de usuário, Heckmann (2005) e Heckmann e Kruguer (2003) propõem uma ontologia¹ de um modelo de usuário geral (*GUMO*). O *GUMO* é um modelo ubíquo de modelo de usuário incluindo muitos aspectos básicos de usuário, partindo desde informação de contato, demográficos, habilidades fisiológicas e psicológicas, estado emocional,

¹Uma ontologia é uma especificação de um conceito.

estado mental e nutrição. A ontologia de Heckmann é muito rica e pode ser implementada de acordo com o interesse do projetista de uma *shell* de perfil de usuário.

Note que para gerar as recomendações e personalizar o ambiente ao usuário, os Sistemas de Recomendação necessitam da identidade interna do usuário que é definida pelo perfil de usuário, como foi apresentado. Porém necessita, muitas vezes, também, da identidade social que é definida pela reputação do usuário.

4.3.2.3 Reputação

Reputação pode ser definida como o retorno social recebido sobre a personalidade de alguém. A reputação pode ser compatível ou não com a descrição feita no perfil de usuário. Josang et al (2007) descreve reputação como “a informação normalmente dita ou crível sobre as características de uma pessoa ou coisa e seus estados”.

Resnick et al. (2000) define reputação como a coleção dos *feedbacks* recebidos sobre o comportamento efetuado pelos participantes de uma comunidade. A reputação ajuda as pessoas a escolher parceiros confiáveis no mundo virtual que são credíveis no mundo real. Geralmente nas redes de reputação, os usuários encorajam os comportamentos confiáveis discriminando a participação de pessoas desabilitadas moralmente ou desonestas.

Segundo Rein (2005) a reputação pode ser também definida como um completo sistema de informações de opiniões alheias sobre um usuário, que inclui todos os aspectos de um modelo de referência. Esse modelo de referência é baseado em nove aspectos determinantes: conhecimento, experiência, credenciais, endosso, contribuições, conexões, sinais, *feedback*, contexto e valores sociais. A visão estrutural de Rein descreve as funcionalidades e comportamentos essenciais do ser humano que são desejáveis e efetivos para possivelmente ser representado através de uma reputação explícita e fácil de ser medida no usuário.

A reputação é geralmente aplicada para gerenciar comportamento do usuário durante um processo comercial (*e-commerce*, por exemplo) envolvendo compra e venda de produtos e/ou serviços e também durante processos sociais como combinação social em comunidades virtuais e redes sociais.

Em processos comerciais, como por exemplo, no *eBay* (Resnick et al. 2000) (Resnick et al. 2006) um consumidor compra um certo produto de alguém. Depois disso, ele deixa um *feedback* sobre o produto comprado e/ou o comportamento do vendedor durante o processo de venda.

Em contraste, em situações sociais como, por exemplo, *Orkut*, *IKarma*, *Opinity*, *LinkedIn*, *Mendeley* (Jensen et al. 2002), usuários são membros de comunidades virtuais ou redes sociais. Eles são capazes de coletar gerenciar e promover reputação de usuário entre seus clientes e contatos da comunidade ou rede. Isto é, usuários (prestadores de serviço) que tem *profile* na rede de reputação, que é também uma rede social podem ser “*tagged*” e rankeados pelos seus clientes e/ou contatos. Usuários podem ser encontrados através de *tags* em e-mail ou, também, alguém pode encontrar um contato de um prestador de serviço simplesmente procurando em *tags* na própria rede de reputação.

Nunes (2009) convencionou reputação como uma extensão de um perfil de usuário. Teoricamente se usa o mesmo tipo de informação armazenada no perfil de usuário, porém o conjunto de informações é fornecido por outro alguém (amigo, cliente do usuário, entre outros). Nesse caso, a identidade é determinada pelos traços de personalidade do usuário informados (ou automaticamente medidos) por ele mesmo para perfil de usuário e informados (ou automaticamente medidos) por uma outra pessoa para reputação de usuário.

O perfil de usuário é muito importante para definir a identidade do usuário. Dessa forma o perfil pode prever necessidades e comportamentos do usuário em um ambiente computacional, enquanto a reputação permite a criação de relação de confiança entre membros de uma comunidade

em um ambiente *web*, especialmente em *e-commerce*. A identidade do usuário é muito útil para sua interação social no ambiente computacional.

A seguir, apresentam-se os esforços dos cientistas de Ciência da Computação e Computação Afetiva com o objetivo de padronizar uma forma de armazenamento e padronização da informação afetiva já definida no perfil do usuário e/ou reputação.

4.3.3. Mecanismos para armazenamento da personalidade em computadores

Considerando a grande gama despadronizada de representação afetiva, alguns pesquisadores pertencentes ao W3C Emotion Incubator Group (W3C 2010a) têm ampliado esforços para definição de uma padronização formal da afetividade através de uma linguagem de marcação. A padronização afetiva tem focado, principalmente, na representação de emoções em uma *markup language*, considerando que emoção é o campo da Computação Afetiva historicamente mais desenvolvido. Após esforços iniciais de Heckmann (2005) na criação de uma ontologia completa incluindo diversos aspectos de Personalidade, a partir de 2008, alguns esforços pontuais de pesquisadores, tais como Nunes (2008; 2009; 2010b) tem seguido na direção duma padronização específica modelada através de uma *markup language* intitulada de PersonalityML.

4.3.3.1 XML & Markup Languages

Uma linguagem de marcação é uma forma de definir e identificar a estrutura e o significado do conteúdo em um documento. A especificação XML define um padrão para adicionar marcação a documentos, genericamente, o XML nem define semântica nem um conjunto de elementos pré-definidos, como o HTML. Na realidade, a XML pode ser considerada como uma meta-linguagem para definir linguagens de marcação, fornecendo mecanismos (através de sua especificação) para que se defina elementos e relacionamentos entre eles, para semânticas preconcebidas.

O uso do padrão XML (W3C 2010d) para definição de outras linguagens de marcação é algo amplamente desenvolvido pela comunidade acadêmica (e são extensamente utilizadas comercialmente). Alguns casos fazem parte da própria tecnologia XML, por exemplo, XML Schema e XSLT. No primeiro caso, o padrão XML Schema possui elementos pré-definidos que definem como construir esquemas para instâncias de documentos XML. No caso da XSLT, os elementos definem como um processador deve ler uma instância XML e transformá-la para outro formato texto como, por exemplo, um HTML, um documento em LaTeX ou até mesmo um simples txt. Outros exemplos são: Simple Object Access Protocol - SOAP (W3C 2010b), *Attention Profiling Markup Language* - APML (Angell et al 2010), Extensible MultiModal Annotation markup language - EMMA (W3C 2010c), Emotion Markup Language - EmotionML(W3C 2010a) entre diversas outras².

4.3.3.2 EmotionML & PersonalityML

A EmotionML (*Emotion Markup Language*) versão 1.0 foi apresentada pelo W3C (*WWW Consortium*) em outubro de 2009. Concebida como uma extensão da linguagem de marcação XML, em uma primeira tentativa da comunidade científica para padronizar a representação de emoções. A EmotionML provê elementos para uma linguagem de marcação que chama a atenção ao equilibrar a fundamentação científica e a aplicação prática. A EmotionML é uma linguagem dinâmica, ainda que muito jovem e com uma representação ainda bastante genérica. Apesar de flexível, a EmotionML não leva em consideração outros aspectos que afetam significativamente a correta identificação de uma emoção, como por exemplo a Personalidade.

² Consultar http://en.wikipedia.org/wiki/List_of_XML_markup_languages para uma lista não exaustiva.

Na realidade, apesar de existência de alguns avanços significativos quanto à Personalidade, são relativamente poucos e incipientes os trabalhos que lidam computacionalmente com este aspecto psicológico, e menos ainda aqueles que lidam com seu reconhecimento automático ou mesmo representação computacional (Mairesse et al 2007), (Heckmann 2005), (Nunes 2009), (Nunes et al 2010).

Como descrito anteriormente, pesquisadores em Computação Afetiva têm implementado as emoções explicitamente, mas de forma despadronizada antes do surgimento o da EmotionML. A representação da emoção, ao invés de outros aspectos de Computação Afetiva se tornou possível devido às emoções serem mais facilmente mensuráveis e interpretáveis e poder efetivamente influenciar diretamente na ação-interação dos usuários. As emoções são instantâneas, elas têm uma vida curta, volátil e mudam constantemente, diferentemente da personalidade que é um estado muito mais estável e, normalmente, mantido durante um período de 45 anos. Apesar disso, com base nas pesquisas é possível dizer que a personalidade implica em emoções (Lisetti 2002); cada pessoa ou agente que tem emoções tem uma personalidade; e, geralmente, a personalidade não aparece explicitamente mesmo que influencie as emoções diretamente. Lisetti (2002) descreve um modelo complexo para representar aspectos psicológicos em agentes inteligentes (virtual/real) que interagem socialmente, denominado *Affective Knowledge Representation* (AKR - Representação do Conhecimento Afetivo). No AKR apresenta-se a Personalidade como o topo do modelo hierárquico dos aspectos psicológicos, denotando assim seu maior poder.

Dessa forma, considerando que a personalidade é mais abrangente e implica na emoção, Nunes et al (2010b) propõem uma extensão à representação padronizada de emoção incorporando uma nova proposta intitulada de PersonalityML, que é também baseada em XML. Essa extensão objetiva representar a complexidade afetiva descrita brevemente em (Nunes et al 2010b), onde a personalidade é o ponto chave da cadeia e, que sua representação está limitada pela atual versão da EmotionML.

Entretanto, antes de se pensar em uma linguagem de marcação para a personalidade, deve-se lembrar que nem todas as teorias de Personalidade existentes possuem uma estrutura passível de representação e, conseqüentemente, de implementação em computadores. Felizmente há algumas que possuem, sendo as mais utilizadas na literatura da Computação Afetiva, àquelas pertencentes à abordagem dos Traços, teoria esta que serviu de base para o lançamento da primeira versão da PersonalityML (Bezerra et al 2011) sendo modular suficiente para a incorporação automática de novas teorias e abordagens existentes hoje. Dessa forma, após a formalização e criação de mecanismos de armazenamento, abaixo apresenta-se como a personalidade pode ser extraída do usuário.

4.3.4. Extração de personalidade

Considerando a abordagem de traços, escolhida por ser a melhor forma para representação de personalidade em computadores, psicólogos geralmente usam questionários intitulados de inventários de personalidade. Esses inventários são diretamente aplicados por psicólogos ou encontrados na *web*. Os mesmos podem ter uma pequena ou grande quantidade de questões e o número de questões é diretamente proporcional a granularidade e precisão dos traços de personalidade extraídos do usuário. Segundo Gosling (2008), os longos e mais precisos inventários tomam um tempo bastante considerável do usuário e muitas vezes torna inviável sua aplicação, nesses casos opta-se pelo uso de testes compactos como o TIPI (estando ciente da limitação quanto a precisão das respostas) ou mesmo opta-se pelo uso de outras formas de extração de personalidade, muitas vezes em estágio embrionário de desenvolvimento. Inicialmente apresenta-se ao leitor a forma clássica de extração de personalidade seguindo-se por abordagens embrionárias e direções de pesquisa:

4.3.4.1 Extração de Personalidade através de inventario baseado em Traços

Existem diversos inventários validados, como apresentado em (Nunes 2009; 2010). Porém um Teste de personalidade bastante interessante é o NEO-IPIP (Johnson 2000), (Johnson 2005) desenvolvido em conjunto com o *International Personality Item Pool* (Goldberg *et al* 2006). Ele permite medir as cinco dimensões do Big Five incluindo mais seis facetas para cada dimensão (30 facetas no total) usando uma descrição detalhada dos traços de personalidade humana e por conseqüência propiciando uma grande precisão na representação da personalidade.

Segundo Gosling (2008) “deixamos pistas sobre nossa personalidade em tudo o que fazemos, em nossos objetos, onde vivemos”. Sendo assim, através dos padrões de navegação de cada usuário, é possível adquirir características psicológicas, através de uma abordagem implícita e transparente ao usuário. Um pensamento natural é que esta seria a melhor forma de obtenção dos traços de personalidade dos usuários, uma vez que esta abordagem exige menor esforço cognitivo se comparado aos tradicionais inventários de personalidade. Porém, Dumm *et al* (2009) negaram esta hipótese ao pesquisar três interfaces de obtenção de traços de personalidade, sendo duas delas explícitas e uma implícita. O resultado foi que a interface NEO (utilizada nos testes como NEO-PI-R e NEO-IPIP) obteve melhor *feedback*, tanto em termos de resultados apresentados quanto em termos de facilidade de uso. Dessa forma, o teste NEO-IPIP, citado acima, torna-se, então, uma opção interessante a ser utilizada como ferramenta de entrada de dados explícita para obtenção dos traços de personalidade dos usuários. Este teste possui um *feedback* positivo em mais de 99% dos casos (Johnson 2005).

Assim, a equipe da autora propôs uma nova interface ao NEO-IPIP, intitulada *Personality Inventory*, oferecendo mais usabilidade ao ambiente proposto originalmente por Johnson (2000) e Gosling (2008). As medições de personalidade extraídas no inventário seguem os padrões propostos por Johnson (2000) e Gosling (2008). Para que os resultados pudessem ser mantidos em um local seguro e persistente e serem usados em diversas aplicações de pesquisa, optou-se por uma aplicação *web*. A interface é simples como apresentado na Figura 1a. Os inventários disponíveis estão apresentados na Figura 1b.

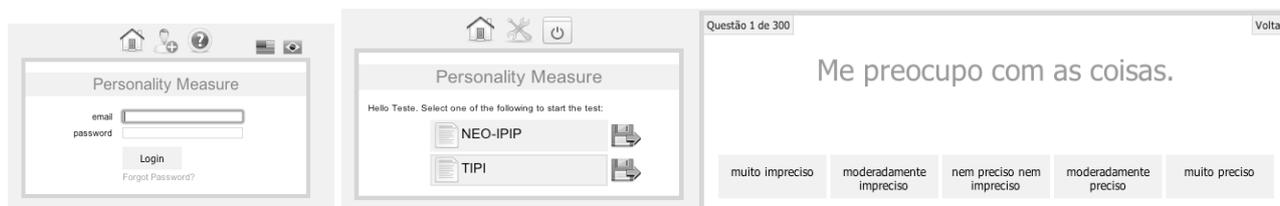


Figura (1a) Interface inicial (1b) Inventários Disponíveis (1c) Questão 1 do inventário

Como visto na figura 1a, para que a medição de personalidade seja feita, o usuário precisa criar uma conta de usuário e responder pelo menos um dos questionários disponíveis, no caso, o NEO-IPIP, como apresentado na figura 1b. Após a seleção do Inventário NEO-IPIP o usuário deve responder o questionário como apresentado na figura 1c.

Uma vez respondido o questionário do NEO-IPIP, cada questão respondida pelo usuário tem valor atribuído entre 1-5. Ao finalizar o teste, os valores atribuídos a cada uma das questões respondidas são utilizados para calcular o resultado. No cálculo, o resultado é normalizado e é atribuído um valor entre 1-100 para cada um dos itens do Big Five, bem como para as suas facetas. Note que somente então o relatório descritivo dos traços de personalidade do usuário é gerado e disponibilizado exclusivamente a ele. Na Figura 2, parte do relatório descritivo dos traços de personalidade do usuário, extraído do inventário NEO-IPIP, é apresentado.

Uma vez visualizado seu prognóstico, o usuário poderá re-visualizar o resultado através da própria aplicação ou exportá-lo como PersonalityML.

4.3.4.2 Extração de Personalidade através de outras técnicas

Note que Gosling (2008) afirma que a melhor forma de obtenção dos traços de personalidade dos usuários é através do uso de uma abordagem que não exija esforço cognitivo se comparado aos tradicionais inventários de personalidade, como o exemplo mostrado acima. Andrade et al (2011) afirma que os traços medidos através de inventários de personalidade muitas vezes são, em parte, um conjunto de dados provenientes do auto-relato da própria opinião do usuários podendo desvirtuar da sua real personalidade.

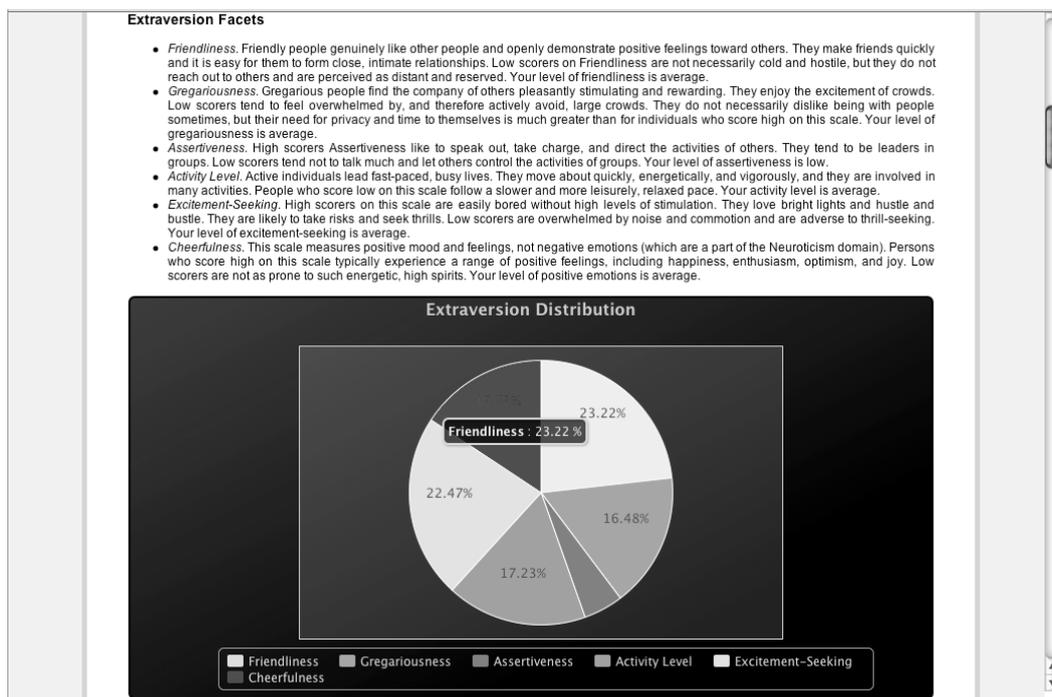


Figura 2. Relatório descritivo parcial do NEO-IPIP (Nunes 2010)

Porém, infelizmente, em computadores, ainda poucas técnicas de extração de traços de personalidade, que diferem dos tradicionais inventários, tem sido desenvolvidas e implementadas. Segundo Brinkman e Fine (2008) constantemente pesquisadores tem se aventurado em novas pesquisas que tentam obter personalidade de uma forma menos intrusiva que os tradicionais inventários. Segundo Porto et al (2011) tem-se realizado tentativas através da análise de gravações automáticas de dados da interação do usuário com o sistema, tais como a avaliação a escolha dos usuários para customização de algumas aplicações como *Windows Media Player*, *ICQPlus* e o *Winamp*, por exemplo.

Andrade e Nunes (2011) afirmam ainda, que nesse novo contexto, incluem-se as técnicas de Reconhecimento de Padrões, baseadas em cálculos probabilísticos visando reconhecer emoções ou mudanças de comportamento através da observação de um usuário utilizando o determinado sistema em uso no computador, seja pelo clique do *mouse*, por teclagem, captura de imagem do usuário pela *webcam* ou, ainda, por sensores que capturam sinais vitais dos usuários (as principais referências são os trabalhos de (Chanel 2009), (Hu and Pu 2009), (Tkalčič 2010) e (Khan et al 2008)). Rabelo e Nunes (2011) ainda afirmam que é possível identificar traços de personalidades a partir de definições de modelos e Frameworks que utilizam recursos estatísticos para classificar

determinado conjunto de dados, definido com conjunto de características, como pertencentes a um determinado traço de personalidade, associada a classes no reconhecimento de padrões. Autores como Mairesse e Walker (2005; 2008); Hussain e Calvo (2009) ; Pianesi et al (2008) convergiram as suas técnicas e modelos à identificação de personalidade a partir de extratos de diálogos de diversas modalidades, tais como: comunicação textual assíncrona (*e-mails* e dialogo em sites de relacionamento), conversa falada (áudio presencial ou virtual), expressões faciais (videoconferência), sinais fisiológicos, dentre outros. Ainda Gill e Oberlander (2003) alegam a possibilidade de detecção de traços de personalidade em textos de comunicação assíncrona, mas explicitamente as mensagens de correio eletrônico através de processos estatísticos.

Abaixo, de acordo com, Rabelo e Nunes (2011) e Porto et al (2011) alguns trabalhos que envolvem extração de traços de personalidade, são melhor detalhados:

- Em Porto et al (2011), a extração de traços de personalidade é realizada através do teclado é feita obtendo-se informações de como o usuário digita determinado texto, essa informação pode ser obtida através da latência entre teclas consecutivas (o tempo entre o apertar de uma tecla e da subsequente). Esse tempo é obtido através de um evento de teclado, o *keyPress*. O evento aciona um *timer* que é interrompido quando o evento é acionado novamente, ou seja, o *timer* conta o tempo decorrido entre uma tecla pressionada e outra, o tempo de latência. Tendo a informação de como um usuário digita, este pode ser comparado com um banco de dados que contem informações de outros usuários, informações estas que são o ritmo de digitação e a personalidade do usuário, e através de técnicas de agrupamento de dados (*clustering*), o usuário é isolado em um grupo que tem o mesmo padrão de digitação, e então os traços de sua personalidade são inferidas a partir dos usuários que fazem parte do mesmo grupo. Os testes realizados para essa abordagem tendem a confirmar que quando os usuários são agrupados levando em consideração o ritmo de digitação, alguns traços de personalidade são correlacionados. Usuários que são agrupados num mesmo cluster tendem a ter o mesmo valor para algumas facetas, e, portanto usuários que não se soubessem o valor das facetas, tendo sido agrupados em um cluster, poderiam ter seus valores inferidos pelos outros elementos do mesmo cluster.
- Gill e Oberlander (2003) investigam o impacto da iteração mediada por computador na percepção pessoal, em particular as características importantes para a socialização e colaboração, Extroversão e Neuroticismo, determinando que tais características podem ser detectadas a partir do texto de um e-mail e para a determinação das características linguísticas da personalidade destes, um conjunto de análises e técnicas foram aplicadas: Os dados LIWC(Linguistic Inquiry Word Count), base de dados e propriedades psicolinguísticas de derivados do *Medical Research Council*, além da medida de diversidade léxica conhecida com *Type Token Ratio* (TTR).
- Por sua vez, Mairesse e Walker (2005) propõem em seu trabalho uma modelagem para reconhecimento de personalidade em conversação, intitulado de *Personality Recognizer*, a partir de uso de modelos estatísticos não lineares para classificação baseada em traços de personalidade do Big Five. A abordagem pode ser resumida em cinco etapas: (1) Recolher individual dos Corpora (Textos); (2) Coletar informações de personalidade para cada participante; (3) Extrair características relevantes a partir dos textos; (4) Construir modelos estatísticos das avaliações de personalidade com base nas características; (5) Testar os modelos aprendidos nas saídas linguísticas dos indivíduos invisíveis. Os dados consistem extratos de conversas diárias de 96 participantes, utilizando um gravador ativado eletronicamente durante o período de dois dias. Para preservar a privacidade dos participantes, bits aleatórios de conversa foram registrados, e somente as afirmações dos participantes foram

transcritas, tornando-se impossível reconstruir conversas inteiras. O corpus contém 97.468 palavras e 15.269 declarações e o experimento foi dado através das etapas seguinte: (1) Seleção de Recursos: Recursos são automaticamente extraídos de cada trecho e é calculada a proporção de palavras em cada categoria a partir da ferramenta LIWC (Linguistic Inquiry Word Count), correlacionando ao Big Five. Estas características psicológicas adicionais foram computados pela média de contagens de palavras características de um banco de dados psicolinguística MRC; (2) Modelos Estatísticos: O treinamento dos modelos foi feito utilizando o algoritmo RankBoost, que classifica de acordo com cada característica do Big Five expressando a aprendizagem dos modelos como regras, que suportam a análise das diferenças nos modelos de personalidade, onde para cada extrato da conversa, a regra modifica a pontuação e assim o ranking. Os resultados obtidos são os aspectos caracterizam a produção de linguagem: (1) Tipos de expressão, conteúdo e sintaxe (LIWC); (2) As estatísticas psicolinguísticas (MRC); (3) Prosódia. Para avaliar como cada conjunto de recursos contribui para o resultado final, foram treinados os modelos com o conjunto completo de recursos e com cada conjunto, individualmente e testes T pareado mostram que os modelos de extroversão, afabilidade, consciência e abertura ao novo usando todos os recursos são melhores do que a linha de base aleatória. O Neuroticismo é o traço mais difícil de modelar, mas é melhor predito por características MRC. As características LIWC têm desempenho significativamente melhor do que a linha de base para todas as dimensões. As características prosódicas são boas predictoras de extroversão.

- Finalmente no trabalho estudado, Pianesi et al (2008) propõe um modelo para reconhecimento multimodal de traços de personalidade em interações sociais, que consiste em criar classificadores capazes de prever os traços de personalidade, considerando o comportamento de um sujeito em um minuto de uma janela temporal. Como classificador, foi utilizado Maquinas de Vetor de Suporte (SVM), que tenta encontrar um hiperplano que não só discrimina as classes, mas também maximiza a margem entre elas. Como experimento, pressupõe-se que a personalidade aparece no comportamento social e é esperado que características audiovisuais fossem apropriadas para constituir um sistema automático de exploração e classificação de traços de personalidade. Duas abordagens são descritas: Na primeira abordagem, leva-se em consideração apenas o comportamento do sujeito é suficiente. Ex.: Maneira como se move entonação da voz e etc. Na segunda leva-se em consideração além do comportamento do sujeito, também o contexto social. Foram testadas as seguintes dimensões: Características Acústicas e Características Visuais e divididas em Níveis distintos: ALL(Todas as características Acústicas + Todas as Características Visuais), SEL (Seleções de características Acústicas + Seleções de Características Visuais) e No-Feat (Todas as características Acústicas + Características Visuais ; Características Acústicas + Todas as Características Visuais, etc). A Combinação destes níveis , exemplo (ALL , No-Feat) corresponde a um vetor de características utilizadas para treinar e testar os Classificadores que serão responsáveis por definir as distribuições dos dois traços de personalidade determinados como classes: A Extroversão e O Locus de Controle. Foram comparados os resultados das classificações com um classificador trivial que atribui a classe mais frequente para cada instancia. Os resultados do experimento determinaram que, duas análises de Variância, uma para cada tipo de personalidade mostram que os principais efeitos são significativos para $p < 0,0001$. Os efeitos para Extroversão não foram significativos em $p > 0,05$, enquanto os efeitos para Locus de Controle foram significativos em $p < 0,05$.

4.4. Tomada de decisão computacional & Sistemas de recomendação

4.4.1. Sistemas de Recomendação

Segundo Resnick e Varian (1997) muitas vezes é necessário fazer escolhas sem um grande conhecimento das possibilidades que nos são apresentadas. Normalmente nos baseamos nas recomendações de amigos, através de opiniões de especialistas ou, ainda, a partir de guias. Os Sistemas de Recomendação ajudam e aumentam este processo social natural já existente entre as pessoas.

Estes sistemas se tornaram uma importante área de pesquisa com os primeiros trabalhos sobre filtragem colaborativa e filtragem baseada em conteúdo em meados da década de 90 (Adomavicius e Tuzhilin, 2005). O interesse nesta área continua grande por ela ser rica em problemas de pesquisa e pela quantidade de aplicativos desenvolvidos para ajudar os usuários a lidar com a imensa demanda de informação, gerando recomendações personalizadas, conteúdos e serviços para os mesmos.

De acordo com Cazella et al (2010), as pessoas têm acesso a uma vasta gama de informações devido à grande oferta e aos recursos da Internet, porém despendem muito tempo na busca do que realmente é interessante ou útil para elas. A dificuldade de encontrar a informação correta é aumentada quando a informação disputa a atenção de uma pessoa com uma série de outras informações não tão relevantes.

Resnick e Varian (1997) afirmam ainda que um sistema típico agrega e direciona as avaliações de itens feitas pelos usuários e as disponibiliza como recomendações para os indivíduos considerados potenciais e interessados neste tipo de recomendação. 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. O sistema gerará respostas mais valiosas quando as preferências dos usuários diferirem uma das outras do que quando temos uns poucos especialistas.

4.4.2. Técnicas de recomendação

Ao contrário da recuperação de informação, onde o usuário necessita informar sua necessidade de informação e é o responsável pelo início da interação, as técnicas de filtragem buscam informações relevantes geralmente através de um perfil de interesses do usuário. A seguir serão descritas algumas técnicas de recomendação (filtragem de informação) aplicadas a Sistemas de Recomendação.

4.4.2.1. Filtragem Baseada em Conteúdo

A filtragem baseada em conteúdo (FBC) realiza uma seleção baseada no conteúdo dos itens (Adomavicius e Tuzhilin 2005). Seu objetivo é gerar de forma automatizada descrições sobre o conteúdo dos itens e compará-las com os interesses do usuário (Herlocker 2000; Ansari 2000). Através disso, pode-se verificar qual a correlação entre o que o usuário está buscando e o item apresentado (Balabanovic e Shoham 1997).

A limitação da técnica está diretamente interligada com os objetos que este sistema necessita recomendar. Portanto, é necessário que o conteúdo dos itens seja computado automaticamente ou, então, será preciso que estas informações sejam adicionadas manualmente, como por exemplo, com a associação de descritores (*tags*). Enquanto existem técnicas que funcionam bem com o processamento de documentos de texto, alguns outros domínios têm problemas com a extração automática. Exemplos são: informação multimídia, imagens, áudio e vídeo (Ansari 2000).

Um grande desafio nessa área é o tratamento de metadados. A forma de identificar o conteúdo dos atributos e conseguir inferir que, por exemplo, “gripe” tem o mesmo significado de “resfriado” em determinado contexto. Para solucionar este problema, tem sido amplamente utilizada a técnica de indexação de frequência de termos (*term frequency indexing*) (Herlocker 2000).

Neste tipo de indexação, as informações sobre o item e as necessidades do usuário são descritas por vetores com uma dimensão para cada palavra da base de dados. Cada componente do vetor representa as repetições da respectiva palavra no item. Assim, os metadados serão ordenados por frequência e quanto mais próximos estiverem ao índice, mais relevante o mesmo será. Obviamente, métodos de pré-processamento de texto são necessários para que palavras muito usadas em notícias e artigos (tais como preposições, artigos e conjunções) não sejam as palavras com maior frequência, prejudicando a predição de conteúdo.

Um problema que pode ocorrer é não conseguir distinguir dois itens caso sejam representados pelo mesmo grupo de características. Portanto, se dois artigos forem representados pelas mesmas palavras, não será possível mensurar a qualidade dos documentos (Ansari 2000).

Os usuários têm a liberdade de poder mudar de opinião e de hábitos. Sistemas de recomendação usando FBC podem tornar-se superespecializados quando o sistema já aprendeu demais sobre os hábitos daquele usuário, e não conseguirem sugerir coisas que fujam desse padrão. Um bom exemplo é o caso de um usuário que consome carne e que se tornou vegetariano. Não importa quanto tempo passe, o sistema vai continuar indicando carnes para compra. Este problema também não possibilita ao usuário receber recomendações de itens que ele já tenha gostado. Desta forma, uma pessoa que nunca tenha experimentado cozinha grega, jamais irá receber a sugestão de visitar o melhor restaurante grego da cidade (Ansari 2000).

Segundo Adomavicius e Tuzhilin (2005), uma forma de tentar resolver o problema da superespecialização é sugerir, aleatoriamente, alguns itens ao usuário. Adicionalmente, deve-se prestar atenção nos itens que são muito similares aos anteriormente vistos, pois o usuário deve receber recomendações homogêneas. Por exemplo, não é necessariamente uma boa idéia recomendar todos os filmes de Woody Allen para alguém que tenha gostado de um deles.

O problema do novo usuário também está presente nesta técnica. Acontece quando o sistema não consegue entender as preferências do mesmo, pelo fato de não ter avaliado uma quantidade mínima de itens, não gerando nenhuma recomendação. E, ainda, caso o usuário não possua muitas recomendações, a qualidade destas também pode ser baixa.

4.4.2.2. Filtragem Colaborativa

Para Cazella (2006), a essência dos sistemas colaborativos está na troca de experiências entre as pessoas que possuem interesses comuns. Para tanto, ao invés do conteúdo dos itens, a filtragem é baseada nas avaliações feitas pelos usuários daqueles itens.

A filtragem colaborativa (FC) 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 FBC 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 produto caso o fizesse. Esta técnica também é chamada de “*k-nearest-neighbor*” ou “*user-based*” (Herlocker 2000).

Um ponto fraco da FC é o seu desempenho. Ela tem de ser rodada *online*, e caso seja executada para todos os usuários, leva-nos a um desempenho de $\Omega(N^2)$ (limite assintótico inferior). Uma heurística poderia ser aplicada no passo intermediário, descartando vizinhos que fogem de um

padrão pré-estabelecido ou que não possuam a nota que se busca predizer (a fórmula de correlação necessita que todos os vizinhos utilizados possuam a nota do produto que se busca fazer a predição). De acordo com Adomavicius e Tuzhilin (2005), pode-se, também, calcular a similaridade de todos os usuários com antecedência e recalculá-la apenas de vez em quando, pois os pares não costumam mudar drasticamente em um curto espaço de tempo.

Também está presente nesta técnica o problema do cold start ou novo usuário. Quando este não possui muitos itens avaliados, o sistema não consegue encontrar usuários similares. Isso se deve ao fato do cálculo da correlação do coeficiente de Pearson necessitar que todos os usuários vizinhos tenham itens em comum para a predição de um item. Algumas estratégias foram propostas para superar esse problema, como a criação de agentes autônomos e a utilização de promoções ou alguma forma de incentivo para aumentar a participação do usuário. Dificuldade similar enfrenta o novo item quando há a sua inclusão no sistema e não é possível recomendá-lo até que algum usuário avalie o mesmo.

Os sistemas baseados em FC também são muito suscetíveis à falhas, segundo Sandvig et al (2007), pois sua busca é baseada em usuários singulares que possuam similaridade, não havendo nenhuma filtragem prévia para verificar se o usuário é um ruído na base de dados. Uma alternativa citada pelo autor é a utilização de regras de associação que, por tentar identificar padrões na base de dados, acabam não sendo tão afetadas por amostras pequenas de ruído. Essas regras, depois de extraídas, poderiam ser aplicadas como heurística no passo intermediário, como comentado previamente.

A esparsidade de uma base de dados é representada pela quantidade de itens não avaliados, ou seja, as células em branco na matriz Usuário X Item. Quanto mais alta a esparsidade, maior também é a dificuldade de encontrar usuários similares e de consequentemente gerar recomendações utilizando a FC.

4.4.2.3. Filtragem Baseada em Informação Contextual

Adomavicius e Tuzhilin (2011) afirmam que contexto é um conceito estudado por diferentes disciplinas como Ciência da Computação, Filosofia, Psicologia, etc. Cada área tende a construir sua própria visão, que é normalmente um pouco diferente das outras.

A fim de trazer uma visão mais genérica, Dourish (2004) introduz a taxonomia de contextos, classificando-a em duas visões: representacional e interacional. A primeira visão, representacional, define contexto como um conjunto de atributos observáveis, possíveis de serem descobertos *a priori* e que não variam significativamente sua estrutura no tempo. Em contraste, a visão interacional assume que o comportamento do usuário é induzido por certo contexto, não sendo necessariamente observável.

Focando em Sistemas de Recomendação e nas áreas de pesquisa relacionadas, vários atributos podem ser utilizados para compor um contexto, como por exemplo, a intenção ao realizar uma compra, localização, identidade de pessoas próximas, objetos ao redor, estação do ano, temperatura, status emocional, personalidade, tempo e companhia do usuário. O contexto também pode ser aplicado ao usuário ou à aplicação.

A informação contextual, devido a sua complexidade, pode ser composta por uma estrutura hierárquica possível de ser representada em formato de árvores (Adomavicius e Tuzhilin 2011). Um exemplo de hierarquia de contexto relacionado a programa televisivo: Programa: Programa □ Subgênero □ Gênero □ Canal; Tempo: Hora □ Data □ Dia da Semana □ Mês □ Ano.

Em vários domínios, como por exemplo recomendar um pacote de férias, um conteúdo personalizado em um site *Web*, produtos em uma loja *online* ou um filme, seria interessante

incorporar informação contextual no processo de recomendação, tais como usuários, itens, tempo e lugar. De acordo com Giordani (2006), a criação de contextos de interesse aumenta as possibilidades de definir o momento mais adequado para recomendar certo produto e, principalmente, quais os produtos que devam compor o perfil do usuário em determinado contexto.

As técnicas de filtragem estudadas aqui utilizam uma função R (Equação 1) e se baseiam exclusivamente nas variáveis usuário e item.

$$R: \text{Usuário} \times \text{Item} \rightarrow \text{Avaliações} \quad (1)$$

A Filtragem Baseada em Informações Contextuais incorpora informação contextual no processo de recomendação, dentro do cenário de decisão do usuário, tais como usuários, itens, tempo e lugar, criando, desta forma, uma função R (Equação 2) com a utilização do contexto:

$$R: \text{Usuário} \times \text{Item} \times \text{Contexto} \rightarrow \text{Avaliações} \quad (2)$$

Alguns tipos de informação contextual podem ser mais relevantes para certo tipo de aplicação do que para outros. Para determinar a relevância de certa informação, um especialista no negócio ou um arquiteto de sistemas de recomendação pode manualmente definir a importância, como também utilizar recursos de aprendizado de máquina, mineração de dados e estatísticas sobre as avaliações já existentes. Segundo Giordani (2006), a construção de contextos individuais não é tão simples pois o analista de negócios deveria efetuar uma análise dos dados transacionais de cada cliente em particular, para então tentar identificar possíveis contextos. Neste caso, fica clara a inviabilidade das análises manuais em função da massificação dos dados, tornando necessária a utilização de artifícios que permitam uma descoberta automatizada computacionalmente.

4.4.2.4. Filtragem Baseada em Outros Contextos

Tkalčič et. al. (2009) afirmam que no contexto de TVD, Sistemas de Recomendação que ignoram as experiências afetivas do usuário enquanto o mesmo está consumindo conteúdo multimídia são no mínimo estranhos, devido ao fato de a indústria do entretenimento estar baseada em causar emoções nas pessoas.

De acordo com a visão de McDonald (2003) a mudança mais importante a se desenvolver na nova geração de Sistemas de Recomendação é a devida complexidade na construção do modelo/perfil de usuário e, o uso apropriado desse modelo. Considerando Perugini et al (2004) modelos/perfis de usuário propiciam indiretamente conexões entre pessoas possibilitando e direcionando a recomendações mais eficientes. Dessa forma, acredita-se que perfis de usuário devem representar diferentes e ricos aspectos da experiência diária de um usuário, considerando a vida real como modelo.

Considere o percurso de um sistema de computador para atingir a mínima compreensão desta otimizada interação de como os humanos procedem nos seus processos de recomendação na “vida real”. Note que humanos usam em suas recomendações informações mais complexas que informações efetivamente usadas por um computador. Isto é, usualmente, sistemas computacionais usam informações tais como competências, preferências, informações demográficas dos usuários, entre outras, para a tomada de decisão e posterior recomendação de uma informação, produto ou serviço. Em contraste, humanos, quando tomam decisões, recomendam e personalizam informações, produtos e serviços para outros humanos, além de usar as informações convencionais usadas pelos sistemas computacionais tendem, também, a usar informações adicionais relacionadas

a habilidades sociais e psicológicas humanas, tais como, traços de personalidade e Emoção (Nunes and Aranha 2009).

Mesmo sabendo ser impossível perfeitamente antecipar as necessidades humanas individuais para recomendar o produto certo, sabe-se que quanto mais ricas forem as informações sobre o usuário, mais precisos serão os produtos, serviços e /ou pessoas recomendadas. Basta observar o que ocorre na vida real.

Nessa linha, note que Nunes (Nunes 2009) expande o modelo inicial de técnicas de recomendação proposto por Gonzalez et al (2007). Gonzalez por sua vez expande o modelo proposto por Burke (2002). O modelo de Burke (2002) categoriza as técnicas de recomendação em cinco: baseada em conteúdo, filtragem colaborativa, demográfica, baseada em conhecimento e baseada em utilidade. Gonzalez et al (2007) por sua vez cria uma nova categoria intitulada recomendação baseada em outros contextos, incluindo aspectos Psicológicos, tais como, Inteligência Emocional e Interação Social, usando como fonte um Perfil de usuário baseado em contextos diferenciados dos tradicionais modelos demográficos ou baseados em preferência do usuário.

Considerando esse aspecto Nunes (2009) ao expandir o modelo proposto por Gonzalez et al (2007), apresenta a personalidade do usuário como um fator relevante na otimização das recomendações ao usuário, como apresentado na Figura 3.

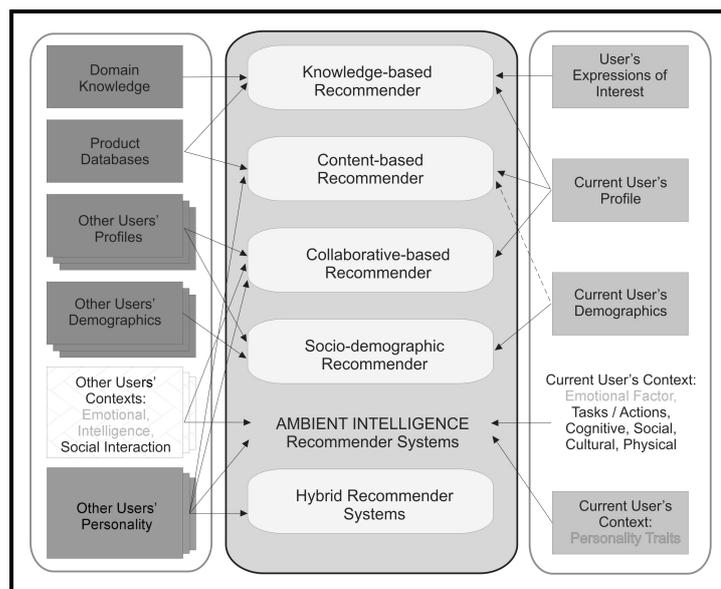


Figura 3. Sistemas de Recomendação baseado em personalidade (Nunes 2009)

A técnica de recomendação baseada em personalidade geralmente é aplicada juntamente a outra técnica como a filtragem colaborativa e/ou baseada em conteúdo, representando uma técnica de recomendação híbrida.

Note que para que seja viável a recomendação baseada na personalidade do usuário necessita-se a representação da personalidade, cada projetista de sistema pode usar uma abordagem diferenciada.

Cazella et al (2010) afirmam que a técnica baseada em personalidade geralmente é aplicada juntamente a outra técnica como a filtragem colaborativa e/ou baseada em conteúdo, constituindo-se numa técnica de recomendação híbrida.

4.4.2. 5. Filtragem Híbrida

A filtragem híbrida busca unir múltiplas técnicas de recomendação a fim de aproveitar o melhor delas (Sandvig et al 2007). É possível, ainda, combinar duas diferentes técnicas do mesmo tipo, como por exemplo, duas diferentes técnicas baseadas em conteúdo. Uma outra alternativa, é manter os perfis dos usuários baseados em uma análise de conteúdo, comparando-os diretamente, por meio de uma recomendação colaborativa, para determinar possíveis semelhanças (Herlocker 2000; Ansari 2000).

Segundo Herlocker (2000), todas as técnicas baseadas em conhecimento (baseada em conhecimento, baseada em conteúdo, colaborativa e demográfica) sofrem com o problema do *cold start* de uma forma ou outra, seja para tratar de novos itens ou novos usuários. Porém, a junção de técnicas de tipos diferentes é indicada para tentar resolver este problema (Sandvig et al 2007).

Com o uso da filtragem híbrida e utilizando os benefícios da filtragem colaborativa e da filtragem baseada em conteúdo, consegue-se a descoberta de relacionamentos entre usuários, a recomendação de itens baseado na avaliação dos mesmos, o tratamento de usuários incomuns e a precisão independente do número de usuários e avaliações (Cazella 2006).

4.4.3. Algoritmos de recomendação

A seguir serão descritos brevemente dois algoritmos aplicados a sistemas de recomendação.

4.4.3. 1. Algoritmo para Filtragem baseada em conteúdo

A Filtragem Baseada em Conteúdo parte do princípio de que os usuários tendem a interessar-se por itens similares aos que demonstraram interesse no passado. Desta maneira, é definida a similaridade entre os itens. Em alguns casos, pode haver maior dificuldade para estabelecer esta similaridade (Adomavicius et al 2005). Para que seja estabelecida a similaridade entre itens como roupas e brinquedos, por exemplo, seria necessária a identificação dos atributos nos itens a serem comparados (peso, preço, marca, por exemplo). No caso dos itens serem artigos científicos (ou documentos), o processo de comparação pode ser focado nos termos que compõem estes textos (Selton e McGill 1983).

Para que seja estabelecida a similaridade entre artigos (ou documentos), este processo de comparação pode ser facilitado, pois documentos podem ser considerados similares se compartilharem termos em comum. Sendo assim, a filtragem baseada em conteúdo é mais indicada para a recomendação de itens textuais, onde o conteúdo é geralmente descrito com *keywords* (Selton e McGill 1983). Um exemplo é o sistema de recomendação Fab, o qual recomendava páginas *web* para usuários. Este sistema representa uma página *web* com os seus 100 mais importantes termos. Similarmente, o sistema Syskill & Webert representa os documentos com as 128 palavras mais significativas (Adomavicius et al 2005).

Outros exemplos de filtragem baseada em conteúdo são sistemas booleanos de recuperação, onde a consulta constitui-se um conjunto de palavras-chave combinadas com operadores booleanos; sistemas de filtragem probabilística, onde o raciocínio probabilístico é utilizado para determinar a probabilidade que um documento possui de atender as necessidades de informação de um usuário; e linguagem natural (Herlocker 2000).

Conforme mencionado anteriormente sistemas de recomendação baseados em conteúdo podem recomendar itens similares a itens que o usuário gostou no passado. Deste modo, vários itens são comparados com itens que foram avaliados positivamente e os mais similares serão recomendados ao usuário. Conforme apresentado por Adomavicius et. al. (2005) pode-se formalizar esta definição estabelecendo *ContentBasedProfile(c)* como sendo o perfil do usuário *c*. Este perfil é

obtido através de uma análise do conteúdo dos itens previamente avaliados pelo usuário utilizando técnicas de recuperação de informação. Por exemplo, $ContentBasedProfile(c)$ pode ser definido como um vetor de pesos (wc_1, \dots, wc_k) onde cada peso wc_i denota a importância do termo k_i para o usuário c utilizando-se a medida TF-IDF (*term frequency–inverse document frequency*).

Em sistemas de recomendação baseados em conteúdo, a função utilidade $u(c,s)$ é geralmente definida conforme a equação (3):

$$u(c,s) = score(ContentBasedProfile(c), Content(s)) \quad (3)$$

Tanto o $ContentBasedProfile(c)$ do usuário c como o $Content(s)$ podem ser representados como vetores (TF-IDF) de pesos e termos \vec{w}_c e \vec{w}_s . Além disso, a função utilidade $u(c,s)$ normalmente é representada, na literatura de recuperação de informação, por algum tipo de pontuação heurística sobre vetores, como por exemplo, a medida de similaridade do cosseno. O cálculo para a medida de similaridade do cosseno pode ser feito de acordo com a equação (4) (Adomavicius et al, 2005):

$$u(c,s) = \cos(\vec{w}_c, \vec{w}_s) = \frac{\vec{w}_c \cdot \vec{w}_s}{\|\vec{w}_c\|_2 \times \|\vec{w}_s\|_2} = \frac{\sum_{i=1}^k w_{i,c} w_{i,s}}{\sqrt{\sum_{i=1}^k w_{i,c}^2} \sqrt{\sum_{i=1}^k w_{i,s}^2}} \quad (4)$$

Onde k é o número total de palavras no sistema. Desta forma, o cálculo de similaridade é realizado computando o cosseno do ângulo formado pelos dois vetores que representam os documentos (termos e frequências) (Adomavicius et al 2005). Esta abordagem é utilizada no protótipo desenvolvido para calcular a similaridade entre os artigos. Por exemplo, se o usuário c , lê muitos artigos relacionados ao tópico Engenharia de Software, as técnicas de filtragem de conteúdo estão aptas a recomendar outros artigos de Engenharia de Software para o usuário c . Estes outros artigos são recomendados porque possuem termos em comum, que neste exemplo, são termos do domínio Engenharia de Software. Neste caso, a função $u(c,s)$ será alta, pois os pesos calculados para os termos destes artigos (que compartilham termos em comum referente ao assunto Engenharia de Software) serão altos (Adomavicius et al 2005).

4.4.3. 2. Algoritmo para Filtragem Colaborativa

A técnica de filtragem colaborativa (FC) possui um modelo conceitual de operação de fácil entendimento, possibilitando analisar itens a serem recomendados sem preocupar-se com o conteúdo destes itens e sim focando nas avaliações dos itens. A operação de um sistema de recomendação por filtragem colaborativa é similar a recomendação verbal de pessoa para pessoa. Os usuários são supridos de recomendação seguindo três etapas:

- 1) usuário fornece seu perfil de avaliações;
- 2) a FC identifica usuários com perfis similares (vizinhos);
- 3) as avaliações dos vizinhos são combinadas para se gerar as recomendações. Com isso, a percepção do usuário dos passos, relacionados anteriormente, afetará sua percepção sobre todo o sistema.

A seguir as etapas serão detalhadas: na Etapa 1, calcula-se o peso em relação a similaridade do usuário-alvo (aquele que deverá receber uma recomendação) e os demais usuários. Isso pode ser calculado aplicando, por exemplo, o coeficiente do Co-seno ou o coeficiente de Pearson (Cazella, et al 2010); na Etapa 2, seleciona-se, a partir dos resultados do cálculo da similaridade, um subconjunto de usuários com maiores níveis de similaridade, que serão denominados vizinhos. Estes vizinhos serão considerados no cálculo da predição do item a ser recomendado; na Etapa 3, normaliza-se as avaliações fornecidas pelos usuários ao item em análise para recomendação e

calcula-se a predição, ponderando-se as avaliações dos vizinhos com seus respectivos pesos de similaridade.

A Tabela 1 apresenta na prática como a filtragem colaborativa funciona. Por exemplo, se quisermos recomendar um produto ao usuário Mauro, procuraremos outros usuários com hábitos de consumo semelhantes. No caso, Paulo e João já compraram produtos que Mauro também comprou (*Prod2*). Em seguida, recomendamos a Mauro produtos que estes dois outros usuários possuem, mas que Mauro ainda não possui, como *Prod1* e *Prod5*. A decisão sobre a recomendação destes produtos baseia-se no histórico de avaliações comuns e o valor de predição calculado.

Tabela 1. Recomendação baseada em filtragem colaborativa

Usuário	Prod ₁	Prod ₂	Prod ₃	Prod ₄	Prod ₅	Prod ₆
Paulo		x			X	
João	x	x				
Márcia			x	x	X	
Carlos			x			
Ana	x			x		
Mauro	?	x			?	

4.4.3. 2. 1. Cálculo do Coeficiente de Similaridade

Para o cálculo da similaridade pode-se adotar o coeficiente de Pearson, uma vez que o mesmo é amplamente utilizado em modelos e mede o grau de relacionamento entre duas variáveis, variando de -1 (ausência total de correlação) a 1 (forte correlação). O cálculo deste coeficiente é realizado conforme a equação 5 (Cazella et al 2010):

$$corr_{ab} = \frac{\sum_i (r_{ai} - \bar{r}_a)(r_{bi} - \bar{r}_b)}{\sqrt{\sum_i (r_{ai} - \bar{r}_a)^2 \sum_i (r_{bi} - \bar{r}_b)^2}} \quad (5)$$

Sendo o $corr_{ab}$ a correlação do usuário alvo a com um determinado usuário b ; r_{ai} : é a avaliação que o usuário ativo a atribuiu para o item i ; r_{bi} : é a avaliação que o usuário ativo b atribuiu para o item i ; \bar{r}_a é a média de todas as avaliações do usuário ativo a , em comum com o usuário b ; \bar{r}_b é a média de todas as avaliações do usuário ativo b , em comum com o usuário a .

4.4.3. 2.2. Predição

A predição é feita independentemente do coeficiente utilizado no cálculo da similaridade, pois ela será gerada através de uma média ponderada das avaliações dos vizinhos que obtiveram um coeficiente de similaridade aceitável, ou seja, com limiar igual ou superior, por exemplo, a 0,3. A equação 6 é utilizada para o cálculo da predição (Cazella et al 2010).

$$p_{ai} = \bar{r}_a + \frac{\sum_{b=1}^n (r_{bi} - \bar{r}_b) * corr_{ab}}{\sum_{b=1}^n |corr_{ab}|} \quad (6)$$

Sendo $corr_{ab}$ é a correlação do usuário alvo a com um determinado usuário b ; p_{ai} a predição de um item i para um usuário alvo a ; \bar{r}_a é a média de todas as avaliações do usuário alvo a aos itens que foram pontuados por todos os seus usuários similares; r_{bi} é a avaliação que o usuário ativo b atribuiu para o item i ; \bar{r}_b é a média de todas as avaliações do usuário b , em comum com o usuário a .

4.5. Exemplos práticos de uso de personalidade para tomada de decisão computacional

Considerando que os estudos realizados nesse capítulo demonstram uma nova tendência à renovação dos Sistemas de Recomendação, onde os aspectos psico-afetivos humanos devem ser considerados na tomada de decisão computacional, aqui apresenta-se alguns exemplos.

4.5.1. e-commerce, e-services

4.5.1.1. Hu and Pu (2009a)

Segundo a visão de Pina e Nunes (2011) o trabalho relata um estudo realizado com usuários para elicitare as preferências entre duas abordagens de sistemas de recomendação: baseado em classificação e baseado em teste de personalidade.

Hu e Pu argumentam que tecnologias de recomendação foram incorporadas a uma série de aplicações, especialmente para sites de *e-commerce* como ferramentas poderosas para ajudar a lidar com a sobrecarga de informações de usuários e prestação de serviços personalizados. Diante desta constatação Hu e Pu realizaram um experimento para comparar dois sites de recomendação de filmes. Para tanto foram adotados os sistemas : *MovieLens*³ e *WhattoRent*⁴.

Para execução do experimento foram feitas algumas adaptações na interface do *MovieLens* para que as diferenças existentes entre ele e o *whattorent* não afetasse a satisfação dos usuários no sistemas. Foi adicionado um link atrelado a cada filme recomendado que exibe um pequeno o clipe do filme. O objetivo é de ajudar o usuário no processo de avaliação dos filmes recomendados. Foi também inserido um grupo de botões ao lado de cada filme recomendado para facilitar aos usuários o fornecimento das avaliações em cinco níveis que vão de muito desinteressada até muito interessado.

O experimento foi feito com 30 participantes, sendo 11 mulheres e 19 homens, distribuídos em quatro grupos etários e com diferentes profissões (cada usuário recebeu umauxilio financeiro como motivação). Cada um dos participantes avaliou os dois sistemas de recomendação (*MovieLens* e *WhattoRent*).

A execução do experimento foi no gabinete de um administrador que supervisionava a experiência e ajudava os participantes a concluir todas as tarefas com sucesso. A seguir são listados os passos do experimento: (i) Participante registra uma nova conta para evitar quaisquer influências a partir do histórico de uso; (ii) No *MovieLens* o participante classifica 15 filmes que tenha visto antes e no *whattorent* o participante responde a 20 questões de personalidade; (iii) São respondidas duas perguntas sobre o atual humor do usuário; (iv) O participante classifica 6 filmes recomendados em uma escalas que vai de 1 = muito desinteressado a 5 = muito interessado; (v) O participante responde um questionário de avaliação on-line onde cada pergunta é respondida em uma escala *Likert* sobre as preferências entre os dois sistemas e suas razões.

Os critérios de avaliação utilizados foram: (i) Percepção de Precisão - Mede quanto os usuários sentem que as recomendações correspondem às suas preferências; (ii) Esforço do Usuário - Mede a

³ O *MovieLens* é um sistema de recomendação baseado em classificação, foi construído pelo grupo de pesquisa GroupLens liderado por John Riedl da Universidade de Minnesota. O *MovieLens* aprende as preferências dos usuários a partir de suas avaliações e utiliza a tecnologia de filtragem colaborativa para recomendar filmes. Quando um novo usuário faz logon, ele é obrigado a informar pelo menos 15 filmes que já tinha visto. Estas classificações são usadas para construir o perfil de usuário e encontrar os ‘vizinhos’ que têm gostos similares ao do presente usuário. Com base na classificação a partir desses vizinhos, ele prediz quanto o usuário possivelmente irá gostar de um filme. Em seguida, ele apresenta todas as recomendações de Filmes em ordem decrescente dos escores previsto. Usuários podem refinar os seus perfis de preferência classificando mais filmes e também podem alterar as classificações anteriores em interações futuras com o sistema.

⁴ O *whattorent* é um sistema de recomendação baseado em personalidade, foi construído com base na Teoria *LaBarrie* que afirma que os “telespectadores interagem emocionalmente com um filme da mesma maneira que eles interagem com outros seres humanos”. Seus desenvolvedores elaboraram um questionário com 20 questões de personalidade onde as preferências dos usuários são decifradas e é feita a recomendação do filme.

quantidade de esforço subjetivo que os usuários sentiram que gastaram e o tempo real que foi utilizado para completar processo de preferência; (iii) Fidelidade do Usuário- Avalia se o sistema tem a capacidade de convencer seus usuários a adquirir o produto recomendado, se o sistema gera interesse de reutilização ou o sistema é satisfatório ao ponto do participante fazer uma indicação para os seus amigos; (iv) Os resultados mostram que a percepção da precisão entre os dois sistemas não é significativamente diferente. No entanto, os usuários gastam muito menos esforço para completar o perfil de preferência baseado em personalidade do que no sistema baseado em classificação. Além disso, os usuários expressaram forte intenção de reutilizar o sistema baseado em personalidade e apresentá-lo aos seus amigos. Após analisar os resultados do questionário final sobre preferência, foi possível constatar que 53,33% dos usuários (16 em 30) preferiram o sistema baseado em teste de personalidade, enquanto que 13,33% dos usuários (4 em 30) preferiram o sistema baseado em classificação.

As autoras acreditam que a principal contribuição do artigo foi perceber quanto a extração de preferências baseada em abordagens de personalidade pode ajudar aos usuários a revelar as preferências ocultas e assim aumentar a precisão recomendação. Ainda o artigo demonstrou a preferência dos usuários por sistemas de recomendação baseado em personalidade. Uma das razões que justificaram essa preferência foi a redução do esforço. Porém os usuários que preferiram a recomendação convencional justificaram a sua preferência considerando a vantagem importante de ter controle sobre a criação do seu próprio perfil.

4.5.1.2. *Hu and Pu (2009b)*

Segundo Pina e Nunes (2011) esse trabalho complementa o trabalho apresentado na seção anterior. O artigo avalia a aceitação de usuários aos sistemas de recomendação baseado em personalidade (RBP), usando o modelo de aceitação de tecnologia (TAM).

O artigo utiliza o mesmo experimento da seção anterior porém utiliza uma formalização melhor para referenciar os resultados. O experimento, como descrito anteriormente foi realizado com 30 participantes, sendo que cada um dos participantes avaliou os dois sistemas de recomendação (*MovieLens* e *WhattoRent*).

A avaliação usou os critérios baseados no modelo TAM, que foi projetado para compreender a relação causal entre variáveis externas de aceitação dos usuários e o uso real do computador, buscando entender o comportamento deste usuário através do conhecimento da utilidade e da facilidade de utilização percebida por ele (DAVIS et al 1989). Segundo Davis et al (1989) as pessoas tendem a usar ou não uma tecnologia com o objetivo de melhorar seu desempenho no trabalho, esse fator é chamado de utilidade percebida. Porém, mesmo que essa pessoa entenda que uma determinada tecnologia é útil, sua utilização poderá ser prejudicada se o uso for muito complicado, de modo que o esforço não compense o uso, esse fator é chamado de facilidade percebida. É também avaliado o critério de intenções comportamentais para uso. Onde são avaliados três aspectos: intenção de compra, a intenção de voltar ao sistema e a intenção de recomendar este sistema para amigos.

Em relação a utilidade percebida - os filmes recomendados pelo sistema baseados em personalidade foram avaliados como de interesse 54,9%, comparados àqueles recomendados pelo sistema baseado em classificação com 42,7% de interesse. Em relação a facilidade de uso - o esforço global cognitivo percebido é significativamente menor no sistema baseado em personalidade do que no sistema baseado em classificação. Em relação as intenções comportamentais de uso – nos três aspectos os RBP obteve um vantagem. Os resultado final encontrado da comparação de aceitação entre os dois sistemas de recomendação mostram que

53,33% dos usuários preferiram o sistema baseado em personalidade em relação a 13,33% do usuários que preferiram o sistema baseado em classificação.

Assim o artigo permitiu concluir a preferência dos usuários entre sistemas de recomendação baseado em personalidade e sistema de recomendação baseado em classificação. E também revelou percepções sobre o processo de escolha do usuário, mostrando que um design de interface simples, pouco esforço inicial, e recomendação de boa qualidade são os fatores mais influentes que contribuem para a aprovação dos usuários nos sistemas de recomendação.

A pesquisa mostrou que a personalidade é um fator de resistência primária e que determina os comportamentos humanos e que são significativas as ligações entre a personalidade e os interesses das pessoas. Sistemas de recomendação baseados em personalidade podem fornecer informações e serviços mais personalizados, desde que eles compreendam melhor os clientes sob o ponto de vista psicológico.

4.5.1.3 Recio-Garcia et al (2009)

Segundo Pina e Nunes (2011) o artigo apresenta um novo método de realizar recomendações para grupos usando a técnica de filtragem colaborativa e considerando a composição da personalidade do grupo. A abordagem utiliza personalidades de membros do grupo para escolher o filme mais interessante que pode melhor satisfazer todo o grupo. A partir dos algoritmos de recomendação clássicos foram feitas três adaptações diferentes utilizando como base o Peso Modo Conflito (CMW) aplicado aos membros do grupo. A pesquisa foi testada no domínio de recomendação de filmes, usando os dados *MovieLens* em conjunto com grupos de usuários de diferentes tamanhos e graus de homogeneidade.

Os autores relatam que conflito é uma parte natural de nossas interações com os outros. Diferentes pessoas têm diferentes expectativas e desejos que geralmente parecem ser incompatíveis. Em situações de conflito, pode-se descrever o comportamento de um indivíduo sob duas dimensões básicas: (i) Assertividade - medida em que a pessoa tenta satisfazer suas próprias preocupações; (ii) Cooperativismo - medida em que a pessoa tenta satisfazer as preocupações das outras pessoas.

O teste TKI (Instrumento Modo Conflito Thomas-Kilmann) foi escolhido pois se concentra na gestão de conflito. O TKI constrói um perfil do usuário por meio de 30 perguntas de escolha única. O teste fornece pontuações para enquadrar o usuário dentre os modos: Competitivo, Colaborativo, Acomodado, Comprometido e Cauteloso. Os cinco modos representam as preferências do indivíduo quando têm que enfrentar situações de conflitos. Estas pontuações são normalizadas utilizando uma amostra de 8.000 pessoas. O Valor do Peso Modo Conflito (CMWU) representa o comportamento do indivíduo após a avaliação TKI. É calculado usando a seguinte equação: $CMW = 1 + \text{Assertivo} - \text{Cooperativismo}$. A seguir a Tabela 2 demonstra a escala de pontuação dos cinco modos utilizada para extrair o nível assertivo ou cooperativo do indivíduo para serem utilizados na equação para encontrar o CMWU:

Tabela 2. Tabela dos coeficientes para calcular CMW Fonte: (Recio-Garcia et al 2009)

TKI Mode	Assertiveness		Cooperativeness	
	High	Low	High	Low
Competing	0.375	-0.075	-0.15	0
Collaborating	0.375	-0.075	0.375	-0.075
Compromising	0	0	0	0
Avoiding	-0.375	0.075	-0.375	0.075
Accommodating	-0.15	0	0.375	-0.075

No contexto de recomendações para grupos as principais abordagens para gerar preferência de grupos com base nas preferências de um usuário são: (i) Fusão das recomendações feitas para os

indivíduos (união ou interseção); (ii) Agregação de indivíduos para classificação; (iii) Construção de um modelo de preferência do grupo. Nesse estudo foi escolhida a abordagem (ii) para recomendação de grupo onde se assume que um indivíduo fornece previsões de classificação para cada usuário do grupo e para cada item a ser recomendado.

Foram implementados três algoritmos de recomendação de grupo a partir do algoritmo básico para que incluíssem o CMW de uma forma diferente. Posteriormente foram feitas comparações entre os resultados das três versões. Os algoritmos são: (i) Minimizando penalização - Este algoritmo utiliza o CMW para calcular o quão interessante é o melhor conjunto de itens candidatos da recomendação de um membro para as outras pessoas do grupo; (ii) Média de satisfação - Este algoritmo é inspirado no procedimento médio de satisfação, o critério de seleção escolhe n itens com maior média de satisfação; (iii) Menor sofrimento - Este algoritmo propõe representar uma variação do procedimento de minimização do sofrimento empregados pelas classificações inferida pelo *MovieLens* para gerar a agregação de preferências.

Os autores apresentaram um experimento com um conjunto de 70 alunos no domínio de recomendação de filmes. Os alunos preencheram suas preferências sobre os filmes dentre uma lista com 50 filmes heterogêneos selecionados a partir do conjunto de dados do *MovieLens*. Em média os usuários avaliaram 33 filmes. Em um outro momento os alunos fizeram o teste TKI, possibilitando o cálculo do Valor Peso Modo Conflito (CMW) para cada indivíduo. Na seqüência o CMW é aplicado nos três algoritmos já citados para obter as recomendações para os grupos.

Para avaliar os resultados foi feita uma comparação usando uma medida simples de avaliação que conta quantos filmes classificados pelo usuário estão no conjunto dos melhores filmes sugeridos pelo sistemas de recomendação. Ao analisar os resultados dos algoritmos com a aplicação do fator CMW foi possível constatar que o algoritmo minimização penalizações funciona melhor propondo apenas um filme. Com a adoção do algoritmo média de satisfação e menor sofrimento é refletida uma melhoria geral na precisão da recomendação. Os resultados também melhoram quando aplicados em grupos com pessoas que tenham soluções de conflito de personalidades heterogêneas.

O artigo contribui demonstrando que sistemas de recomendação para grupos poderiam ser melhorados em até 7% de precisão ao utilizar os valores da personalidade dos indivíduos obtidos a partir do TKI e CMW.

4.5.2. TV digital (Trevisan 2011)

Uma aplicação para recomendação de programas de TV (Trevisan 2011) pode rodar 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. Com o surgimento da TV Digital no Brasil e a crescente expansão do sinal, a possibilidade do desenvolvimento de programas interativos tornou acessível a criação deste tipo de sistema. Então, utilizando o SBTVD, foram testadas as duas plataformas do Ginga (Ginga NCL e Ginga-J) para o desenvolvimento do protótipo da aplicação. O Ginga NCL foi o que apresentou maior maturidade e que possui o maior número de aplicações sendo desenvolvidas no cenário nacional, até por conta da maior maturidade que possui. Os testes foram realizados no emulador XletView que utiliza uma implementação de referência do MHP (*middleware* do padrão europeu). O XletView é um emulador de TVD baseado no *middleware* MHP que permite a execução de xlets em um ambiente PC. É um projeto de *software* livre e está sob a licença GNU GPL. Um xlet é uma aplicação Java para TVD e equivale a um applet Java em um PC (Araujo e Carvalho 2009).

O protótipo em TVD implementado 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. A base de dados de programas de televisão foi disponibilizada pela empresa Revista Eletrônica para o presente trabalho e pôde ser obtida via FTP, no formato XML. A grade de programação utilizada no protótipo foi extraída entre 21/06/2010 a 05/07/2010 (quinze dias). A fim de viabilizar o experimento e devido à quantidade de usuários e o tempo de experimentação, foi decidido pela importação de somente programas dos canais abertos da televisão brasileira: o SBT, a RBS, a Bandeirantes, a TV COM, a TV Futura e a Rede TV. Desta forma, foi obtida uma base de dados com uma esparcialidade não tão alta e com programas mais conhecidos.

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. Como os contextos são configuráveis, é possível a aplicação de um algoritmo de mineração de dados no momento em que há a posse de uma base de dados com uma quantidade maior de avaliações e extrair novos contextos, talvez mais significativos. Os contextos elencados para a execução do protótipo foram por exemplo, 1) Nome do contexto: Sozinho; Descrição: Adulto assistindo sozinho; Aparelho: Televisor; 2) Nome do contexto: Com Crianças; Descrição: Acompanhado de crianças; Aparelho: Televisor; 3) Nome do contexto: Recebendo Amigos; Descrição: Recebendo amigos para um jantar; Aparelho: Televisor; 4) Nome do contexto: Com Namorado(a); Descrição: Acompanhado do namorado(a)/esposo(a); Aparelho: Televisor; 5) Nome do contexto: Locomovendo-se; Descrição: Viajando de ônibus para o trabalho; Aparelho: Celular.

A biblioteca Apache Mahout foi utilizada como *framework* para a construção das recomendações. Além de vários outros recursos, ela fornece algoritmos de filtragem colaborativa e baseada em conteúdo, estando sob a licença de software da Apache (Mahout, 2011). Os testes de personalidade foram realizados utilizando a aplicação *Personality Inventory PVI.0* Nunes et al (2010). Esta é uma aplicação *online* que utiliza os testes NEO-IPIP e TIPI. Cada questão respondida tem um valor atribuído entre 1 e 5 (Figura 1c). 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 seleção do contexto em que o usuário se encontra é realizada de forma explícita pelo mesmo antes de receber uma recomendação. Pode ser alterada a qualquer momento, pressionando a tecla verde do controle remoto. Quando a lista é exibida, basta clicar com a tecla de comando “para cima” e “para baixo” do controle remoto até posicionar sobre o contexto desejado e, então, pressionar o botão “ok” do mesmo, conforme a Figura 4.

Uma vez definido o contexto do usuário, o sistema acessa o servidor e busca uma lista de recomendação para o usuário. É possível que nenhum programa seja recomendado para o usuário, neste momento, pelo algoritmo descrito no modelo do sistema anteriormente. Para que o usuário não fique sem receber nenhuma recomendação, o sistema busca por programas que se enquadrem no contexto selecionado e que possua os gêneros, subgêneros e classificações etárias melhor avaliadas por este usuário no passado.

Neste ponto, o sistema acaba realizando uma filtragem baseada em conteúdo e, desta forma, o usuário não fica frustrado por não receber nenhum item recomendado e acaba com o problema do *cold start*. Outro ponto positivo de recomendar itens mesmo que o algoritmo de filtragem colaborativa não retorne nenhuma recomendação é a alimentação do sistema com o *feedback* do usuário que é enviado para cada recomendação gerada, o que de certa forma contribui para o sucesso das suas próximas utilizações.

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 5). Para navegar pelos itens e avaliá-los, basta que o usuário utilize as teclas de navegação do controle remoto “para cima” e “para baixo” a fim de posicionar-se no item desejado, e a tecla “para esquerda” e “para direita” para aumentar ou diminuir a nota dada para o programa recomendado.

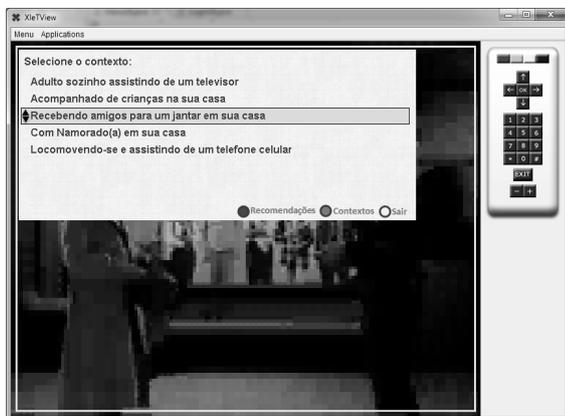


Figura 4 – Seleção explícita de contexto (Trevisan 2011).

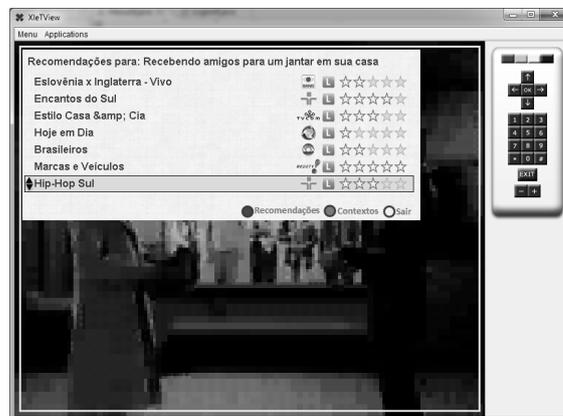


Figura 5 – Lista de recomendações fornecidas pelo TvPlus (Trevisan 2011).

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.

4.5.3. Outros

4.5.3.1. Presidencial Francesa (Nunes 2009)

Nunes (2009) apresenta um protótipo de Sistema de Recomendação que objetiva dar indícios do quão importante os aspectos psicológicos, como traços de personalidade, são no processo de tomada de decisão computacional, isto é, no processo de recomendação (em Sistemas de Recomendação e/ou Sistemas de Combinação Social).

A Presidencial Francesa é um Sistema de Recomendação mostrando sua habilidade para recomendar pessoas, nesse caso, consideradas no contexto de produtos e não prestadoras de serviço⁵.

Cenário: O cenário desse sistema é apresentado pelas “eleições Presidenciais na França” realizada em 2007. Nesse caso, o Sistema de Recomendação foi usado para gerar uma recomendação considerando a melhor escolha de um candidato para uma pessoa votar, considerando a reputação dos candidato sob as vistas da própria pessoa que receberia a recomendação. Esse experimento foi aplicado de dezembro de 2006 a julho de 2007.

⁵ O Sistema de Recomendação gera uma pessoa com um “produto”, pois, nesse caso, a pessoa é considerada como um pacote fechado, ou seja, a pessoa significa verdadeiramente o nome dessa pessoa. Nesse caso, a pessoa não é considerada como um provedor de serviço, como normalmente as pessoas são consideradas. A visão de produto significa que a pessoa recebe uma recomendação de alguém constando um nome a ser considerado como suporte a sua tomada de decisão, diferentemente da visão de serviço. Na visão de serviço, a pessoa recebe um nome para ser usado como um provedor de serviço, isto é, este “nome”(pessoa) irá provavelmente executar algum serviço a posteriori. Na visão de produto, o Sistema de Recomendação gera uma resposta passiva, diferente da visão de serviço onde a resposta, provavelmente, gera uma interação dinâmica com a pessoa que executará o serviço.

Método: Objetivando-se criar um Perfil de usuário adequado à recomendação, esse experimento usou a abordagem de traços de personalidade (já apresentado na seção anterior) proposto por Nunes (Nunes 2009). Então, o Perfil/Reputação Psicológico do Usuário foi criado considerando o teste de personalidade NEO-IPIP (Johnson 2001) baseado em 300 questões.

Cerca de 100 pessoas foram convidadas a participar do experimento. Cada pessoa que participou do experimento foi instruída a responder o NEO-IPIP 3 vezes: (i) uma para o “candidato ideal”, as respostas refletiam como cada pessoa via o que considera características psicológicas de um presidente ideal; (ii) outra para o candidato “Nicolas Sarkozy”, isto é, cada pessoa respondeu o questionário informando como via e o que pensava sobre as características de tal candidato (Reputação); (iii) e outra para a candidata “Ségolène Royal”, isto é, cada pessoa respondeu o questionário informando como via e o que pensava sobre as características de tal candidato (Reputação).

Através das respostas, a modelagem dos aspectos psicológicos dos candidatos, isto é, o Perfil de usuário (Reputação), foi criado. A recomendação⁶ foi feita baseada nesses aspectos psicológicos.

Objetivando validar a precisão da recomendação gerada pelo Sistema de Recomendação, foi requisitado a cada pessoa que participou do experimento gentilmente confirmasse se o resultado da recomendação realmente havia representado o seu *voto real*.

Resultados: Apenas 10% das pessoas requisitadas responderam totalmente o questionário. O Sistema de Recomendação forneceu 2 tipos de recomendação. A primeira recomendação foi baseada nas 30 facetas do Big Five (para mais informação ver Nunes 2009) e, a segunda foi baseada simplesmente nas 5 dimensões do Big Five.

Os resultados da recomendação foram muito mais satisfatórios e representativos que o esperado. Os resultados são: (i) considerando a primeira recomendação, mais precisa (baseada nas facetas), a recomendação foi 100% precisa. Isto é, todas as recomendações geradas pelo Sistema de Recomendações combinaram com os votos efetivos dos participantes; (ii) considerando a segunda recomendação, menos precisa (baseado nas dimensões), a recomendação atingiu 80% de acerto. Isto é, houve 20% de casos onde a recomendação gerada pelo Sistema de Recomendação foi incompatível com o voto efetivo dos participantes.

O resultado demonstrou que usando uma complexidade maior na representação do Perfil Psicológico do usuário, no caso das facetas, o resultado obtido foi muito satisfatório.

O sucesso desse experimento referenciou o grande potencial no uso de questões psicológicas para auxiliar na tomada de decisão computacional através do uso de Sistemas de Recomendação. Ele foi o indicio necessário para apostar nessa nova e potencial tendência a ser usadas nas futuras recomendações.

4.6. Conclusões

Considerando que os Sistemas de Recomendação constituem-se em uma área de pesquisa que apresenta uma série de desafios e oportunidades. Já faz algum tempo que as pesquisas na área saíram da academia e tomaram forma no mercado, sendo inserido como solução em grandes sites de *e-commerce* como *Amazon.com*, *Submarino.com*, e atualmente o próprio site de recuperação de

⁶ O Sistema de Recomendação usou a técnica de recomendação baseada em outros contextos, considerando a personalidade. A abordagem usada na implementação foi algoritmo de busca linear usando a técnica do vizinho mais próximo.

informação Google, implementou uma solução de recomendação, onde o usuário uma vez logado poderá recomendar uma página.

Vimos neste capítulo como os Sistemas de Recomendação dotados de traços de personalidade podem ser utilizados para que se possa conhecer melhor os hábitos de consumo e interesses dos usuários, e como este tipo de conhecimento pode ser empregado para fidelizar clientes *web*.

Ao longo deste capítulo foi introduzida a área Computação Afetiva, incluindo uma breve descrição dos aspectos que envolvem a afetividade enfatizando a Personalidade. Seguindo-se por uma descrição e exemplificação de como, porque e quando a Computação Afetiva, principalmente a personalidade, potencializa a tomada de decisão humana. Apresentou-se, também, as abordagens de personalidade existentes exemplificando as codificáveis em computadores. Discutiu-se como os aspectos de personalidade influenciam na identidade do usuário e como isso afeta seu perfil. Na seqüência, foi descrito os critérios de armazenamento bem como as metodologias existentes hoje para extração de personalidade por computadores. Ainda discutiu-se as formas existentes de tomada de decisão computacional enfatizando os Sistemas de Recomendação, focando em sua aplicação, principalmente em e-commerce e TV digital. Questões relativas a técnicas e estratégias de recomendação foram apresentadas com o resumo de seus algoritmos.

Esse estudo tem mostrado que empresas tem buscando cada vez mais personalizar a relação humano-computador e esta tendência é motivada principalmente pelos interesses do *e-commerce e e-services*. Porém para evoluirmos na área da Computação Afetiva é preciso encontrar as melhores técnicas para capturar a personalidade e o perfil dos usuários. Existem linhas de pesquisa na área da psicologia que acreditam que é possível definir um indivíduo pela sua personalidade, a partir da análise de suas características.

Com o propósito de definir a personalidade surgem várias abordagens, tais como humanística, cognitiva, tipos, traço entre outras. Com base nessas abordagens são construídos modelos para capturar a personalidade. Os trabalhos estudados em sua maioria fizeram uso dos modelos baseados no BIG FIVE/FFM o que aparenta ser uma tendência, visto que, trabalha com a abordagem de traços. As pesquisas, que de modo geral utilizaram experimentos com um número pequeno (em média 60, entre homens e mulheres) de pessoas, demonstram que estes inventários são extremamente necessários à evolução da classificação das recomendações, porém, há estudos que comprovam que estas técnicas são formas invasivas e que desestimulam usuários a respondê-los, por seu extenso volume de questionamentos. Com isso, novos modelos têm sido sugeridos com a finalidade de melhorar a usabilidade do preenchimento destes formulários, associados às ferramentas probabilísticas capazes de otimizar a recomendação, ressaltando a necessidade de pesquisa com outras técnicas estatísticas que se adéquam ao contexto.

Dispositivos de aquisição de dados como teclado e mouse são soluções que não oneram os sistemas e nas pesquisas apresentadas, tem obtido resultados importantes na definição da personalidade e dos estados emocionais. Sensores de detecção de sinais fisiológicos, apesar de onerosos, possuem alta precisão na detecção destas atividades fisiológicas e melhoram bastante a classificação dos estados emocionais. Vimos, também a possibilidade de reconhecer e extrair traços de personalidade através de outra abordagem como diálogos e o uso de modelos estatísticos advindos da técnica de reconhecimento de padrões. Notoriamente, a importância de se reconhecer e responder traços de personalidade automaticamente possibilitaram a automatização nos processos de comunicação, derivando aplicabilidade variada em áreas da ciência, tecnologia e social.

O Sistema de Recomendação é uma tendência mundial quando estamos tratando de problemas que necessitam de apoio à decisão. Os Sistema de Recomendação, de uma forma geral,

tentam melhorar suas recomendações utilizando formulários de intervenção a usuários que buscam serviços e produtos.

Contudo, evidencia-se que um Sistema de Recomendação associado à Filtragem Colaborativa, onde as técnicas probabilísticas garantem uma maior acurácia à recomendação pela medida de similaridade dos usuários, tendo ainda Hardware e Software agregados aos sistemas com finalidades de enriquecer as definições dos modelos de usuário, modelos de itens e modelos de personalidades, são desejos da comunidade de Computação Afetiva na tentativa aproximar cada vez mais a um cenário real.

Alguns desafios emergem neste contexto, tais como: uso da computação afetiva com a utilização de agentes de software ou agentes de comunicação para uma maior interação com o usuário; criação de sistemas eficazes para recomendação a partir da aplicação de traços de personalidade adaptando a interface às reais necessidades psico-cognitivas do usuário, entre desafios que estão ainda surgindo dentro de uma área extremamente promissora no que tange a pesquisa.

Agradecimentos

Gostaríamos de agradecer a todos os alunos (IC, IT, TCC e Mestrado) que orientamos na área de Sistemas de Recomendação e contribuíram na elaboração do material de pesquisa usado na composição desse capítulo, principalmente ao aluno Luiz Trevisan que trabalhou o protótipo TV Plus, o aluno Jonas Santos Bezerra que está desenvolvendo o PersonalityML e a aluna Sandy Porto + Wanderson Costa que estão desenvolvendo um aplicativo para a extração automática de personalidade.

4.7. Referências Bibliográficas

- Adomavicius, Gediminas E Tuzhilin, Alexander. (2011) Context-Aware Recommender Systems. In: Ricci, Francesco Et. Al. Recommender Systems Handbook. Cap. 7, P. 217-253.
- 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, P. 734-749, Los Alamitos.
- Allport, G. W.(1927). Concepts of trait and personality. Psychological Bulletin, (24):284–293. (Available at <http://psychclassics.yorku.ca/Allport/concepts.htm>).
- Andrade, L.O. S.; Nunes, M. A. S. N. (2011) Computação Afetiva: uma breve análise sobre os Sistemas de Recomendação Baseado em Conteúdo e Sistemas de Recomendação de Filtragem Colaborativa. Relatório Técnico- Notas de Mestrado. PROCC-Universidade Federal de Sergipe.
- Ansari, Asim; Essegari, Skander E Kohli, Rajeev. (2000) Internet Recommendation Systems. In: Journal Of Marketing Research, P. 363-375, Chicago.
- Araujo, Sandra R. C. E Carvalho, Victor T. (2011) Emuladores Para Tv Digital - Openmhp E Xletview. Disponível Em: <<http://Www.Tvdi.Inf.Br/Upload/Artigos/Artigo7.pdf>> Acesso Em: 10 Mar.
- Balabanovic, Marko E Shoham, Yoav Fab. (1997) Content-Based, Collaborative Recommendation. In: Communications Of The Acm, P. 66-72, Nova Iorque.
- Bezerra, J. S., Nunes. M. A. S. N., Oliveira. A. A. (2011) Desenvolvimento de metodologias de extração de perfil psicológico de usuário para aplicação em Sistemas de Recomendação objetivando personalização de produtos e serviços em e-commerce. Relatório Técnico de Pesquisa, Universidade Federal de Sergipe.
- Boyd, D. (2002). Faceted id/entity: Managing representation in a digital world. Master's thesis, Cambridge, MA.
- Burger, J.M. (2000). Personality. Wadsworth, fifth edition.
- Burke, Robin. (2002) Hybrid Recommender Systems: Survey And Experiments. In: User Modeling And User-Adapted Interaction, P. 331-370, Hingham.
- Carreira, R., Crato, J.M., Gonçalves, D. and Jorge, J. A. (2004). Evaluating adaptive user profiles for news classification. In IUI '04: Proceedings of the 9th international conference on Intelligent user interfaces, pages 206–212, New York, NY, USA. ACM Press.
- Cazella S. C., Nunes, M. A. S. N., Reategui, E. A. A. (2010) Ciência Da Opinião: Estado Da Arte Em Sistemas De Recomendação. In: Wagner Meira Jr. E André C. P. L. F. De Carvalho(Org.).. (Org.). Jai: Jornada De Atualização Em Informática Da Sbc. Rio De Janeiro: Editora Da Puc Rio, V. , P. 161-216.

- Cazella, S. C.; Correa, I. ; Barbosa, J. ; Reategui, E. (2009) Um Modelo Para Recomendação De Artigos Acadêmicos Baseado Em Filtragem Colaborativa Aplicado À Ambientes Móveis. *Revista Novas Tecnologias Na Educação*, V. 7, P. 12-22.
- Cazella, S. C. (2006) Aplicando A Relevância Da Opinião De Usuários Em Sistema De Recomendação Para Pesquisadores. Tese (Doutorado Em Ciência Da Computação) - Universidade Federal Do Rio Grande Do Sul, Porto Alegre, RS.
- Chanel, G. (2009) Emotion assessment for affective computing based on brain and peripheral signals. Thèse de doctorat : Univ. Genève.
- Damasio, Antonio R. (1994) *Descartes' Error: Emotion, Reason, And The Human Brain*. Quill, New York.
- Davis, F. D.; Bagozzi, R. P. and Warshaw, P. R.. (1989). User acceptance of computer technology: a comparison of two theoretical models. *Manage. Sci.* 35, 8 982-1003.
- Donath, J. S. (2000). Being Real: Questions of Tele-Identity. In: Ken Goldberg, editor, *The Robot in the Garden: Telerobotics and Telepistemology in the Age of the Internet*, chapter 16, pages 296–311. The MIT Press, first edition.
- Donath, J.S. (1999) Identity and Deception in the Virtual Community. In M. A. Smith and P. Kollock, editors, *Communities in Cyberspace*, chapter 2, pages 29–59. Routledge, London, first edition.
- Dourish, Paul. (2004) What We Talk About When We Talk About Context. In: *Personal And Ubiquitous Computing*. P. 19-30.
- Dunn, G., Wiersema, J., Ham, J., and Aroyo, L. (2009) Evaluating Interface Variants on Personality Acquisition for Recommender Systems. In *Proceedings of the 17th international Conference on User Modeling, Adaptation, and Personalization: Formerly UM and AH*. G. Houben, G. Mccalla, F. Pianesi, and M. Zancanaro, Eds. Lecture Notes In Computer Science, vol. 5535. Springer-Verlag, Berlin, Heidelberg, 259-270. (2009)
- Erikson, Erik H.(1980). *Identity and the Life Cycle*. Norton.
- Khan, I., Et Al. (2008) Measuring Personality from Keyboard and Mouse Use. *ACM International Conference Proceeding Series*, Vol. 369. Portugal.
- Giddens, A. (1991) *Modernity and Self-Identity. Self and Society in the Late Modern Age*. Stanford university Press, Stanford, California.
- Gill, A. J. ; Oberlander, J. (2003). Perception of e-mail personality at zero acquaintance: Extraversion takes care of itself; Neuroticism is a worry. *Proceedings of the 25th Annual Conference of the Cognitive Science Society* (pp. 456–461). Hillsdale, NJ: LEA.
- Giordani, Alexandre. (2006) Wine Bunch: Uma Ferramenta Baseada Em Agrupamento Para Auxiliar Na Identificação De Contextos De Interesses De Consumidores Em *E-commerce*. Trabalho De Conclusão De Curso (Graduação Em Análise De Sistemas) - Universidade Do Vale Do Rio Dos Sinos, São Leopoldo, RS.
- Goffman, E. (1959). *The Presentation of Self in Everyday Life*. Anchor Book.
- Goldberg, L. R., Johnson, J. A., Eber, H. W., Hogan, R., Ashton, M. C., Cloninger, R. C., Gough, H. G., (2006) The international personality item pool and the future of public-domain personality measures. *Journal of Research in Personality* 40 (1), 84-96.
- Gosling, S. (2008) *Psiu, Dê Uma Espiadinha! Editora Campus*.
- Gonzalez, G., De La Rosa, J.L., And Montaner, M. (2007) Embedding Emotional Context Inrecommender Systems. In *The 20th International Florida Artificial Intelligence Research Society Conference-Flairs*, Key West, Florida.
- Heckmann, D. (2005). *Ubiquitous User Modeling*. Phd thesis, Technischen Fakultäten der Universität des Saarlandes, Saarbrücken-Germany.
- Heckmann, D. and Kruger, A. (2003). A user modeling markup language (UserML) for ubiquitous computing. In *8th International Conference on User Modeling, LNAI 2702*, page 393-397, Johnstown, PA, USA. Springer, Berlin Heidelberg.
- Herlocker, Jonathan L. (2000) *Understanding And Improving Automated Collaborative Filtering Systems*. Tese - Universidade De Minnesota, Minnesota.
- Hu,R and Pu,P. (2009a). A comparative user study on rating vs. personality quiz based preference elicitation methods. In *Proceedings of the 14th international conference on Intelligent user interfaces (IUI '09)*. ACM, New York, NY, USA, 367-372.
- Hu,R and Pu,P. (2009). Acceptance issues of personality-based recommender systems. In *Proceedings of the third ACM conference on Recommender systems (RecSys '09)*. ACM, New York, NY, USA, 221-224. DOI=10.1145/1639714.1639753 <http://doi.acm.org/10.1145/1639714.1639753>
- Hussain, M. S.; Calvo, R. A. (2009). *A Framework for Multimodal Affect Recognition*. Learning Systems Group, DECE, University of Sydney.
- Jensen, C.; Davis, J. and Farnham, S. (2002). Finding others online: reputation systems for social online spaces. In *CHI '02: Proceedings of the SIGCHI conference on Human factors in computing systems*, pages 447-454, New York, NY, USA. ACM.

- John, Oliver P. E. Srivastava, Sanjay. (1999) The Big Five Trait Taxonomy: History, Measurement, And Theoretical Perspectives. In: Handbook Of Personality: Theory And Research, P. 102–138. 1999. Nova Iorque.
- Johnson, J.A. (2000) Web-based personality assessment. In 71st Annual Meeting of the Eastern Psychological Association, Baltimore, USA. (Available at <http://www.personal.psu.edu/~j5j/vita.html>).
- John A. Johnson. (2001) Screening massively large data sets for nonresponsiveness in web-based personality inventories. Invited talk to the joint Bielefeld-Groningen Personality Research Group, University of Groningen, The Netherlands. (Available at <http://www.personal.psu.edu/faculty/j/5/j5j/papers/screening.html>).
- Johnson, J.A. (2005) Ascertaining the validity of individual protocols from web-based personality inventories. *Journal of research in personality*, 39(1):103–129.
- Josang, A., Ismail, R. and Boyd, C. (2007). A survey of trust and reputation systems for online service provision. *Decision Support Systems*, 43(2):618–644.
- Khan, I. A.; Brinkman, W. P.; Fine, N.; Hierons, R. M. (2008) Measuring Personality from Keyboard and Mouse Use, In: European Conference in Cognitive Ergonomics, Madeira, Portugal.
- Kobsa, A. (2007). Generic user modeling systems. In P. Brusilovsky, A. Kobsa, and W. Nejdl, editors, *The Adaptive Web*, volume 4321 of *Lecture Notes in Computer Science*, chapter 4, pages 136–154. Springer Verlag.
- Konstan, J. A.; Miller, B. N., Maltz, D.; Herlocker, J. L.; Gordon, L. R. and Riedl, J. (1997). GroupLens: applying collaborative filtering to usenet news. *Communications of the ACM*, 40(3):77-87.
- Lisetti, Christine L. (2002). Personality, affect and emotion taxonomy for socially intelligent agents. In *Proceedings of the Fifteenth International Florida Artificial Intelligence Research Society Conference*, pages 397–401. AAAI Press.
- Mairesse, F.; Walker, M..(2006) Automatic recognition of personality in conversation. In *Proceedings of the Human Language Technology Conference of the North American Chapter of the Association for Computational Linguistics (HLT-NAACL)*, New York City.
- Mairesse, F.; Walker, M..(2008) A personality-based framework for utterance generation in dialogue applications. In *Proceedings of the AAAI Spring Symposium on Emotion, Personality and Social Behavior*.
- Mairesse, F., Walker, M.A., Mehl, M.R., Moore, R.K. (2007) Using Linguistic Cues for the Automatic Recognition of Personality in Conversation and Text. *Journal of Artificial Intelligence Research* 30, p. 457-500.
- Mahout. Apache Mahout. (2011) Disponível Em: <[Http://Mahout.Apache.Org](http://Mahout.Apache.Org)>. Acesso Em: 03 Mar.
- McDonald, David W. (2003). Recommending collaboration with social networks: a comparative evaluation. In *CHI '03: Proceedings of the SIGCHI conference on Human factors in computing systems*, pages 593–600, New York, NY, USA. ACM.
- Mead, G. H. (1934). *Mind, Self, and Society*, volume 1. University of Chicago, Chicago, Charles W. Morris edition.
- Nunes, M. A. S. N. ; Cerri, Stefano A. ; Blanc, N.(2008) . Improving Recommendations By Using Personality Traits In. In: *International Conference On Knowledge Management-In: International Conference On Knowledge Management-I.Know08, 2008, Graz-Austria. International Conference On Knowledge Management-I.Know08. V. 1. P. 92-100.*
- Nunes, M. A. S. N. (2009) Recommender Systems Based On Personality Traits: Could Human Psychological Aspects Influence The Computer Decision-Making Process?1. Ed. Berlin: Vdm Verlag Dr. Müller. V.1. 140p.
- Nunes, M. A. S. N. ; Aranha, C. N. (2009) .Tendências à Tomada de Decisão computacional . In: *W3C, 2009, São Paulo. W3C.*
- 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: *Glauco José Couri Machado. (Org.). Educação E Ciberespaço: Estudos, Propostas E Desafios. Aracaju: Virtus Editora, V. 1, P. 308-347.*
- Nunes, M. A. S. N. ; Bezerra, J. S. ; Oliveira, A. (2010b) Estendendo O Conhecimento afetivo da EmotionML. In: *IHC, 2010, Belo Horizonte. IHC2010. Porto Alegre : SBC.*
- Paiva, A. and Self, J.A. (1995). Tagus - a user and learner modelling workbench. *User Model. User-Adapt. Interact.*, 4(3):197–226.
- Perugini, Saverio; Gonçalves, Marcos André and Fox, Edward A. (2004). Recommender systems research: A connection-centric survey. *Journal of Intelligent Information Systems*, 23(2):107–143.
- Pianesi, F. ; Mana, N.; Cappelletti, A. ; Lepri, B.; Zancanaro, M..(2008) Multimodal recognition of personality traits in social interactions. in *Proceedings of the 10th International Conference on Multimodal Interfaces: Special Session on Social Signal Processing, 2008, pp. 53–60.*
- Picard, R. W. (1997) *Affective Computing*. Mit Press, Cambridge, Ma, Usa.
- Pina, E. da C.; Nunes, M.A.S.N. (2011) Os Rumos Da Pesquisa Científica Em Computação Afetiva. Relatório Técnico- Notas de Computação Afetiva. Mestrado-PROCC-Universidade Federal de Sergipe.

- Poo, D., Chng, B. and Goh, J.M. (2003). A hybrid approach for user profiling. In HICSS '03: Proceedings of the 36th Annual Hawaii International Conference on System Sciences (HICSS'03) Washington, DC, USA. IEEE Computer Society.
- Porto, S. M.; Costa, S. W.; Nunes, M. A. S. N; Matos, L. N. (2011) Desenvolvimento de Metodologias de Extração de Perfil Psicológico de Usuário para Aplicação em Sistemas de Recomendação Objetivando Personalização de Produtos e Serviços em E-Commerce. Relatório Técnico de Pesquisa. Universidade Federal de Sergipe.
- Rabelo, R. A. C.; Nunes, M.A.S.N. (2011) Um Estudo Sobre Modelos E Frameworks De Reconhecimento De Personalidade Em Diálogos. Relatório Técnico- Notas de Computação Afetiva. Mestrado-PROCC-Universidade Federal de Sergipe.
- Recio-Garcia, J. A.; Jimenez-Diaz, G.; Sanchez-Ruiz, A. A. and Diaz-Agudo. B. (2009). Personality aware recommendations to groups. In Proceedings of the third ACM conference on Recommender systems (RecSys '09). ACM, New York, NY, USA, 325-328.
- Reeves, B. Nass, C. (1996) The Media Equation: How People Treat Computers, Television, And New Media Like Real People And Places. Cambridge University Press, New York, Ny, Usa.
- Rein, G. L. (2005). Reputation information systems: A reference model. In HICSS'05: Proceedings of the Proceedings of the 38th Annual Hawaii International Conference on System Sciences (HICSS'05) - Track 1, page 26, Washington,DC, USA. IEEE Computer Society.
- Resnick, P.; Zeckhauser, R.; Swanson, J. and Lockwood, K.. (2006). The value of reputation on ebay: A controlled experiment. *Experimental Economics*,9(2):79-101.
- Resnick, P.; Kuwabara, K.; Zeckhauser, R. and Friedman, E. (2000). Reputation systems. *Commun. ACM*, 43(12):45-48.
- Resnick, Paul; Varian, Hal R. (1997) Recommender Systems. In: *Communications Of The Acm*. P. 56-58, Nova Iorque.
- Riedl, J. Et Al. (1997) GroupLens: Applying Collaborative Filtering To Usenet News. *Communications Of The Acm*, New York, V.40, N.3, Pp. 77-87, Mar.
- Rousseau, B., Browne, P. , Malone, P. Foster, P. and Mendis, V. (2004). Personalised resource discovery searching over multiple repository types: Using user and information provider profiling. In *ICEIS (5)*, pages 35–43.
- Salton, G., McGILL J. M. (1983) Introduction to Modern Information Retrieval. McGraw Hill, New York, USA.
- Sandvig, J. J., Mobasher, Bamshad E Burke, Robin. (2007) Robustness Of Collaborative Recommendation Based On Association Rule Mining. In: *Acm Conference On Recommender Systems*. P. 105-112.
- Schafer, J. B.; Konstan, J. and Riedl, J. (1999). Recommender systems in e-commerce. In *EC '99: Proceedings of the 1st ACM conference on Electronic commerce*, pages 158-166, New York, NY, USA. ACM.
- Schafer, J. B.; Konstan, J. and Riedl, J. (2001). E-commerce recommendation applications. *Data Mining Knowledge Discovering*, 5(1-2):115-153.
- Schultz, D. (1990) Theories of Personality. Brooks/Cole, forth edition.
- Simon, H.A. (1983) Reason In Human Affairs. Stanford University Press, California.
- Thagard, Paul. (2006) Hot Thought: Mechanisms And Applications Of Emotional Cognition. A Bradford Book- Mit Press, Cambridge, Ma, Usa.
- Tkalčič, Marko Et. Al. (2009) Personality Based User Similarity Measure For A Collaborative Recommender System. In: *The 5th Workshop On Emotion In Human-Computer Interaction*, P. 279-311, Cambridge.
- Tkalčič, M.; Burnik, U.; Košir, A. (2010) Using affective parameters in a content-based recommender system for images. *User Modeling and User-Adapted Interaction: The Journal of Personalization Research*, Volume 20, Number 4, pages: 279-311.
- Trappl, Robert; Payr, Sabine And Petta, Paolo Editors. (2003) Emotions In Humans And Artifacts. Mit Press, Cambridge, Ma, Usa.
- Trevisan, Luiz. (2011) Tv Plus: Um Modelo De Sistema De Recomendação De Programas Para Tv Digital. Trabalho De Conclusão De Curso (Graduação Em Sistemas De Informação) - Universidade Do Vale Do Rio Dos Sinos, São Leopoldo, RS.
- Salton, G., McGill J. M. (1983) Introduction To Modern Information Retrieval. McGraw Hill, New York.
- Soldz, Stephen E Vaillant, George E. (1998) The Big Five Personality Traits And The Life Course: A 45 Years Longitudinal Study. In: *Journal Of Research In Personality*, P. 208-232.
- W3C 2010a. Emotion Markup Language (EmotionML) 1.0 W3C - Working Draft 29 October 2009. Disponível em: <http://www.w3.org/TR/2009/WD-emotionml-20091029/>. Acesso em 08/06/2010.
- W3C 2010b. SOAP - W3C Recommendation. <http://www.w3.org/TR/soap/> . Acesso em 01/07/2010.
- W3C 2010c. EMMA: Extensible MultiModal Annotation markup language version 1.0. <http://www.w3.org/TR/emma/> . Acesso em 01/07/2010.
- W3C 2010d. XML Specification. WorldWideWeb Consortium. Disponível em <http://www.w3c.org>. Acesso em 01/07/2010.