



TRILHA PRINCIPAL

Personal_Movie – Um modelo de Sistema de Recomendação de filmes geolocalizados em eventos.

Otávio Cordeiro Siqueira de Oliveira, Maria Augusta Silveira Netto Nunes, e Silvio César Cazella.

Abstract—Considering how hard it is to provide more assertive and personalized information, products and service for people/tourists who are searching for a service, such as: having lunch/dinner, searching what's hot about films in theaters right now in the “Olympic villa”, for instance. In order to fill this gap this paper describes a Recommendation System (RS) that applies contextual information and people's personality as recommender inputs in order to predict more personalized films for Cinemark's clients (Personal_Movie). In order to illustrate our discussion we present an experiment that uses a software for mobile that uses geo-location and people's personality to further improve the quality of the film recommendation. The experiment has shown promising results and its potential in the generation of more assertive recommendation. We believe the results might be as applicable for other products and services requested in Brazilian mega events

Keywords-Recommender Systems, Personality, contextual information, Megaeventos.

Resumo- Considerando o quanto é difícil fornecer informações mais assertivas e personalizadas sobre produtos e serviços para pessoas / turistas que estão a procurando por um serviço, tais como: almoço / jantar, ou se existe um filmes que estão em cartaz e que está sendo exibido agora na Villa Olímpica, por exemplo. Para preencher esta lacuna, este trabalho descreve um sistema de recomendação (RS), que utiliza a informação contextual e personalidade das pessoas, como entradas de recomendação, a fim de prever filmes mais personalizados para os clientes Cinemark do (Personal_Movie). A fim de ilustrar a nossa discussão, apresentamos um experimento que usa um software para celular que usa geolocalização e personalidade das pessoas para melhorar ainda mais a qualidade da recomendação filme. A experiência tem mostrado resultados promissores e seu potencial na geração de mais recomendação assertiva. Acreditamos que os resultados possam ser expandidos para outros produtos e serviços solicitados nos megaeventos realizados no Brasil.

Palavras-Chave— Sistemas de Recomendação, Personalidade, Informações Contextuais, Megaeventos.

Otávio Cordeiro Siqueira de Oliveira é aluno de Graduação no curso de Sistemas de Informação (SI) na Universidade Federal de Sergipe (UFS). E-mail: otasiq@gmail.com.

Maria Augusta Silveira Netto Nunes é Professora no Departamento de Computação (DCOMP) da Universidade Federal de Sergipe (UFS). E-mail: gutanunes@gmail.com.

Silvio César Cazella é Professor no Departamento de Computação da Universidade do Vale do Rio dos Sinos (UNISINOS). E-mail: cazella.unisinos@gmail.com

I. INTRODUÇÃO

O Brasil receberá uma quantidade enorme de turistas durante os megaeventos dos próximos anos. Visando a otimização no atendimento a esse público o Ministério do Turismo Brasileiro traçou um perfil desses turistas. O estudo foi realizado durante a copa da África, a fim de identificar potenciais caminhos mercadológicos [13]. Segundo essa pesquisa, o público turístico foi formado principalmente por europeus e norte-americanos, sendo 83% homens, 60% era homens solteiros e 86% concluíram o ensino superior. Cada turista despendeu durante 15 dias no evento em média R\$ 11,4 mil (sem passagem aérea) [21].

Outro resultado importante é o fato de que 80% desses turistas nunca visitaram o Brasil, o que permite concluir que os megaeventos proporcionam uma demanda turística internacional diferente das convencionais, pois esse público é diferente e provavelmente não visitaria o Brasil em outro contexto.

Esse é um desafio dobrado à academia e empresariado, pois ao mostrar um Brasil receptivo, com atividades sócio-econômico sustentáveis e inovação em termos de prestação de serviços, o megaevento pode se tornar um multiplicador de outros potenciais futuros turistas trazendo mais desenvolvimento ao país.

Considerando que o Brasil exporta mão de obra qualificada em ciência da computação, acredita-se que a academia, em conjunto com o empresariado, pode efetivamente criar um legado computacional interessante para ser usado durante e após os megaeventos esportivos.

Objetivando ofertar informações, produtos e serviços de forma personalizada e assertiva à pessoas/clientes/turistas, a comunidade acadêmica brasileira e mundial tem utilizado os recursos de Sistemas de Recomendação (SR). Os SR podem ser criados e aplicados aos mais diversos domínios, tal como na recomendação de filmes em cinemas, por exemplo.

A. Cenário

Desde a sua criação, a indústria cinematográfica tem produzido uma grande variedade de filmes e a cada lançamento várias informações referentes ao filme são disponibilizadas à população em geral (empresários, clientes, etc.). Essas mesmas informações sobre filmes são repassadas aos consumidores/clientes sem muito tratamento, não

chegando de forma acessível e personalizada aos telespectadores (que são os potenciais clientes consumidores).

As informações sobre filmes, normalmente, são disponibilizadas por meio de uma sobrecarga de informação dificultando a escolha da atração personalizada pelo cliente. Esta sobrecarga de informações é uma preocupação antiga [13] e tratar esse problema tem sido um dos desafios dos Sistemas de Recomendação (SR) [20]. Os SR indicam potenciais itens de interesse para usuários. A inserção de informações contextuais como: horário do filme, local de exibição, preço do bilhete do cinema e a censura auxiliam o processo de recomendação refinando-a. Com essas informações colhidas no contexto atual do usuário é possível prever itens de acordo com o contexto no qual o usuário está inserido [31].

Além do uso de informações contextuais é possível aplicar traços de personalidade do usuário, a fim de melhorar o processo de recomendação. Segundo Nunes [24] [25][48] a aplicação de traços de personalidade em Sistemas de Recomendação gera uma melhor recomendação.

A criação de um aplicativo que agregue tecnologias e serviços disponíveis nos dispositivos móveis pode auxiliar a coleta de informações contextuais como: o cinema que está próximo ao usuário, programação desse cinema, etc. O uso do Sistema de Posicionamento Global (GPS) atrelado aos recursos dos sistemas de recomendações pode vir a auxiliar a obtenção de informações contextuais, podendo assim refinar a recomendação e a disponibilização da informação de maneira mais rápida e eficaz.

Nas seções a seguir serão apresentados os seguintes itens: a seção 2 apresenta as características dos SR e suas técnicas. A seção 3 disserta sobre os trabalhos relacionados. Na seção 4 apresenta-se o estudo de caso no cenário descrito anteriormente, seguido pela modelagem, detalhes do Protótipo. O experimento e as discussões serão apresentadas na seção 5. A seção 6 apresenta as conclusões e trabalhos futuros. Finalizando, na seção 7 pelas referências bibliográficas.

II. SISTEMAS DE RECOMENDAÇÃO

Normalmente as pessoas baseiam-se nas recomendações de amigos, nas opiniões de especialistas, ou ainda, em outras fontes, tais como mídias sociais, para tomar uma decisão. Os Sistemas de Recomendação ajudam e potencializam este processo social natural já existente entre as pessoas [27].

Para Resnick e Varian [31] o grande desafio está em descobrir o relacionamento de interesses entre os usuários, buscando prever os itens de maior interesse para eles.

Para prever itens é necessário obter os dados sobre os mesmos. A coleta de dados pode ser realizada de forma explícita ou implícita:

(i) Gadhano e Lhuillier [9] afirmam que a coleta explícita sobre produtos é aquela em que o usuário necessita inferir manualmente suas preferências sobre itens. O problema desta metodologia é que o usuário pode não especificar seus

interesses completamente, podendo assim mascarar possíveis resultados.

(ii) A coleta de dados implícita utiliza técnicas de extração de conteúdo, mineração de texto, entre outras, para que se permita coletar dados do cliente sem que o mesmo perceba. Neste modelo se extraem informações de possíveis áreas de interesse e aplicando técnicas de associação onde é possível sugerir produtos e serviços [9]. A coleta implícita também auxilia na obtenção dos dados do usuário formando/melhorando seu perfil [24].

Segundo Cazella, Nunes e Reategui [4] quanto maior o nível de informações sobre o usuário, mais pertinentes serão as recomendações de produtos, serviços e/ou pessoas. Para a tradução de fatores psicológicos de um indivíduo com o intuito de formação do seu perfil se faz necessário definir a personalidade do indivíduo [10]. Para isso existe uma abordagem bastante interessante sobre o assunto que é a utilização de traços de personalidade que permitem diferenciar psicologicamente pessoas usando traços mensuráveis e conceituáveis [33] [47].

Após a coleta de dados aplicam-se técnicas para recomendar esses itens coletados. Na sessão a seguir serão apresentadas as principais técnicas de recomendação.

Técnicas de Recomendação

As técnicas de filtragem de informação possuem uma interação dinâmica com os usuários, onde a cada nova ação realizada, o algoritmo deve procurar um novo item que atenda às preferências do usuário naquele momento, sendo que esta busca não precisa ser iniciada pelo mesmo.

As principais técnicas para recomendação são as seguintes:

1. A filtragem baseada em conteúdo (FBC): baseia-se exclusivamente nas variáveis Usuários X Item, comparando o conteúdo dos itens às preferências dos usuários. A categorização dos itens é o grande problema desta técnica, pois a busca por informação em um determinado contexto pode modificar o sentido de um metadado. O processo de identificação do conteúdo dos atributos e a diferenciação do sentido dele naquele contexto específico é um grande desafio [1][2].

2. A filtragem colaborativa (FC): utiliza as avaliações realizadas pelos usuários sobre os itens e as compara com as avaliações realizadas por outros usuários. Os autores Adomavicius e Tuzhilin [2] destacam que uma característica importante da FC é que esse modelo utiliza uma técnica de recomendação independente de domínio. Ela é indicada para recomendação de conteúdo que não pode ser descrito adequadamente por metadados.

3. A Filtragem Baseada em Informação Contextual (FBIC): surgiu para suprir a lacuna deixada pelas abordagens tradicionais 2D citadas anteriormente, onde se baseiam apenas em Usuário X Item e que não trata as informações contextuais. Para este modelo, o conceito de contexto está inserido de forma implícita nas atividades

corriqueiras dos seres humanos, além de ajudar na comunicação. Quando o contexto é percebido permite a uma pessoa fazer avaliações, tomar decisões e adaptar seu comportamento de acordo com a situação [1][2][3]. Para que uma pessoa possa tomar decisões de forma apropriada à situação se faz necessário compreender o contexto [34].

4. A Filtragem Baseada em Aspecto Psicológico (FBAP): Segundo González, o fator emocional influencia o pensamento racional quando um usuário recebe qualquer recomendação. Diante disso o autor resolve propor a filtragem baseada em outros contextos, trabalhando aspectos psicológicos, como a Inteligência Emocional e a Interação Social [11]. Diante da abrangência do conceito de contexto, este trabalho propõe uma mudança na nomenclatura proposta por González. O autor propôs “outros contextos”, esse trabalho especializa a nomenclatura em Filtragem Baseada em Aspectos Psicológicos (FBAP) em mais alto nível, sendo Filtragem Baseada em Emoção (FBE) para definir o conceito de contexto quando estiver relacionado a características emocionais de indivíduo. Logo após, Nunes [24] propôs outra abordagem dentro de Filtragem Baseada em Aspectos Psicológicos (FBAP) envolvendo aspectos de personalidade na filtragem, intitulados aqui de Filtragem Baseada em Personalidade (FBP).

5. Nunes [24] definiu de Sistemas de Recomendação baseados em personalidade, depois intitulado por Hu and Pu [13] como PBRs (Personality-based Recommender System). Para capturar a essência das diferenças individuais da personalidade de um indivíduo é comum aplica-se um teste para compreensão da sua personalidade. O teste é uma pesquisa empírica capaz de revelar um conjunto estabelecido de traços do indivíduo, o que acaba por diferenciar um sujeito do outro.

6. Já a Filtragem Híbrida (FH) faz uso de uma ou mais técnicas de recomendação, geralmente combinando uma abordagem colaborativa baseada em conteúdo com a filtragem colaborativa. A FH vem sendo amplamente utilizada em Sistemas de Recomendação, pois utilizam mais de uma técnica de recomendação conjugada para prevenir problemas clássicos de *cold start* (conceituado como o problema da falta de informações iniciais do usuário necessárias para gerar uma recomendação assertiva ao usuário).

O presente trabalho utilizará a FH, pois pretendemos alcançar o objetivo pela metodologia.

III. TRABALHOS RELACIONADOS

Vários trabalhos têm abordado diferentes propostas para a recomendação de produtos como filmes. O NetFlix [6] propõe a utilização de mineração de dados e filtragem baseada em conteúdo, além da coleta de informação de forma implícita, na qual o sistema infere as preferências dos usuários.

Já o MovieLens [23] [38] [39] e o IMDB [15] fazem uso da

FBC e da coleta explícita do usuário na qual o mesmo deve inferir suas preferências sobre itens, além de usar técnicas de FC para melhorar o seu processo de recomendação.

Alguns trabalhos como Jinni [17], HunchMovies [18], WhattoRent [36], a fim de aumentar a eficácia dos SR, têm utilizado a coleta implícita em conjunto com a explícita onde o usuário informa manualmente suas preferências através de questionários, aplicando notas a itens ou selecionando áreas de interesse pessoal.

A filtragem baseada em informações contextuais (FBIC) está presente nos SR's Alfred [42] [43] e DITTO [5]. Esses SR's não recomendam filmes, apenas serviços para usuário utilizando dados do GPS para realizar a coleta de informações contextuais.

O CinemaKI [14] apesar de coletar informações contextuais do usuário, permite recomendar filmes que estão em cartaz nos cinemas de acordo com a coleta explícita realizada pelo serviço. Como não encontramos referências que embasem o tipo de técnica utilizada pelo CinemaKI, efetuamos uma pesquisa exploratória no sistema e estamos inferindo que ele utiliza as técnicas FC.

Apesar de não encontramos referências que embasem o tipo de técnica utilizada pelo Jinni, efetuamos uma pesquisa exploratória no sistema e estamos inferindo que ele utiliza FBP aplicando questionário para extração de personalidade para os novos usuários a fim de obter conhecimento sobre o mesmo [18][41]. No questionário o perfil é traçado de acordo os 12 tipos de observadores de filmes disponibilizados pelo sistema que são: O Introspectivo, O Herói, O Individualista, O Viciado em Drama, O anti-social, O extremista, A Realidade Alternativa, o Idealista, A arte da Fuga, O mestre da Mente, O estrategista e O Filósofo Social.

Segundo Lawler [18] o HunchMovies possui o motor de recomendação inteligente chamado de “*The Living Room*” que gera recomendação personalizada de filmes após ter respondido utilizando FBP e FC, incluindo o gênero mais adequado para que o telespectador provavelmente deva assistir.

Para geração da recomendação o WhattoRent [36][42] usa a

TABELA I
TRABALHOS RELACIONADOS X TÉCNICA DE RECOMENDAÇÃO

	IMDB	MovieLens	NETFLIX	CinemaKI	Jinni	HunchMovies	WhattoRent	Alfred	DITTO	Personal_Movie
Mineração de Dados	?	?	x	?	?	?	?	?	?	
Coleta Implícita	?	?	x	x	?	x	?	x	x	x
Coleta Explícita	x	x	x	x	x	x	x	x	x	x
FC	x	x	x	x	x	x	x	x	x	x
FBC	?	?	?	?	?	?	?	?	?	x
FBIC	?	?	?	?	?	?	?	x	x	x
FBP	?	?	?	?	x	x	x	?	?	x

coleta explícita de dados para obtenção de informações sobre o estado emocional do usuário.

Na tabela 1, é apresentado um comparativo entre os trabalhos relacionados aqui expostos e o modelo do Personal_Movie proposto neste trabalho. Foram elencadas algumas características e marcado com X a presença dela no sistema estudado e com ? a característica que não encontrado referencial para embasar a afirmação do tipo de técnica utilizada. Foi avaliado o método de coleta de informação, a utilização de mineração de dados, a técnica de filtragem de informação, e se o sistema utiliza ou não informações contextuais, FBP, FC e FBC.

Como ilustra a tabela 1 o ponto forte do protótipo proposto aqui é a junção da técnica de FBIC às técnicas FBC, FBP e FC, pois com a coleta de informações contextuais ele poderá gerar uma recomendação mais adequada ao contexto atual do usuário.

IV. ESTUDO DE CASO: PERSONAL_MOVIE

O estudo de caso proposto por este trabalho é um *testbed* da tecnologia para a construção de SR para megaeventos.

O estudo de caso foi baseado em SR de filmes, unindo informações contextuais, sobretudo relacionadas à Geolocalização, e traços de personalidade às tradicionais técnicas de recomendação. (Note que o filme é tratado como um produto podendo assim ser adaptado para qualquer informação, produto ou serviço a ser recomendado nos megaeventos).

As novas abordagens de SR utilizadas para recomendação de filmes auxiliam na predição de filmes que mais se adaptem ao contexto no qual o usuário está inserido.

A. Modelagem do Personal_Movie

Considerando o cenário descrito, a modelagem proposta é a que segue:

No Personal_Movie, as informações contextuais permitem descobrir os filmes que mais se adaptem ao contexto atual do usuário. É realiza então uma pré-filtragem que se dá através da coleta implícita de informações utilizando a FBIC, quando são coletados filmes em cartaz nos cinemas situados próximos ao usuário conforme interação realizada com a interface GPS. Posteriormente à fase de coleta, é feito o armazenamento dos

itens coletados (dados da programação do cinema) na base de dados (figura1).

Os traços de personalidade são obtidos a partir da interação com o *Personality Inventory* [29] (figura 2) que se baseia no modelo *Big Five*, onde trata características: Extroversão, Socialização, Neuroticismo e Abertura nos fatores e outras características nos sub-fatores [46]. Essas informações são incluídas pelo Personal_Movie no processo de FC, afim de, encontrar usuários semelhantes. A utilização de traços de

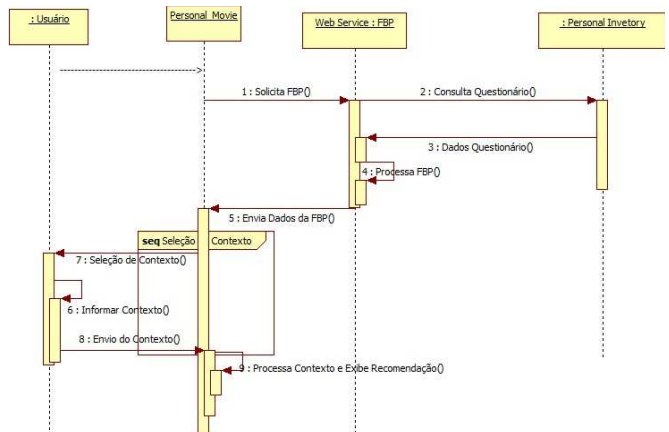


Fig. 2. Diagrama de Sequência para uso da FBAP

personalidade tem o objetivo de tornar o perfil de usuário mais rico.

Com as informações obtidas até então (tanto dos produtos quanto dos usuários) é feito o cálculo de similaridade, que para os itens é baseado na FC enquanto que para os usuários é baseado na FBAP de acordo com características manipuladas pelo modelo Big Five. Os algoritmos que implementam as técnicas de recomendação (FBIC, FC, e FBAP) estão contidos no Web Service do serviço de recomendação, de tal forma que, uma vez geradas as listas de itens recomendáveis, as mesmas são enviadas para o dispositivo móvel (figura 2).

O dispositivo, após receber a lista de itens recomendáveis, executa o ajuste na fase de pós-filtragem (Passos 6,7 e 8 da figura 2) que é definido empiricamente levando em

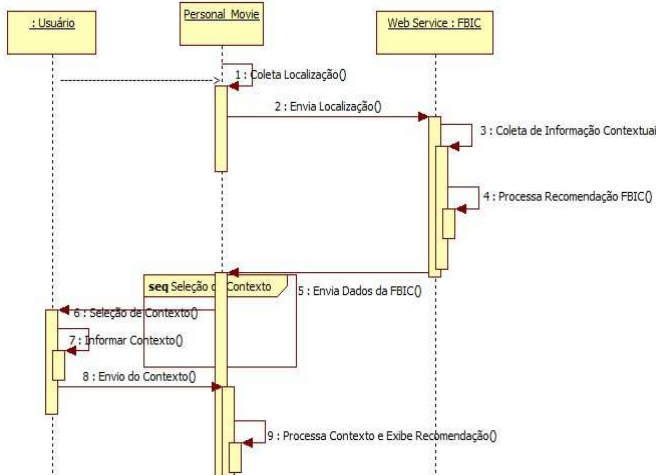


Fig. 1. Diagrama de Sequência para aplicação da FBIC.

Código	Descrição
1	Sozinho
2	Com Crianças
3	Com Amigos
4	Com Namorado (a)
5	Com Compromisso

Fig. 3. Opções de Contexto Previamente Cadastradas

consideração a opção de contexto selecionada pelo usuário. A figura 3 ilustra as opções disponíveis aos usuários para seleção do contexto.

Por exemplo, levando-se em consideração um cenário onde o usuário do Personal_Movie tenha escolhido a opção 5, o que indica que ele possui algum compromisso marcado e não

dispõe de tempo para assistir um longa-metragem, evitando assim que filmes com essa classificação sejam recomendados. Num outro cenário, onde a opção 2 tenha sido escolhida, os filmes com censura maior que 16 anos são excluídos da lista de itens recomendáveis.

B. Protótipo

O Protótipo Personal_Movie utiliza conceito de SOA (Service-Oriented Architecture), que é uma abordagem para criar sistemas computacionais distribuídos baseados no encapsulamento de lógica de negócio em serviços que podem ser acessados de forma fracamente acoplada [7].

O Personal_Movie dispõe de um *webservice* que contém algoritmos responsáveis por implementar a coleta de informações contextuais, bem como a geração de recomendação de filmes geolocalizados. A coleta de informações contextuais é realizada através da interface do dispositivo móvel, após isso as informações são enviadas a um servidor HTTP que contém o *webservice* para processá-las e disponibilizar a recomendação para o usuário. Há ainda a opção de o usuário avaliar se o filme recomendado atende ou

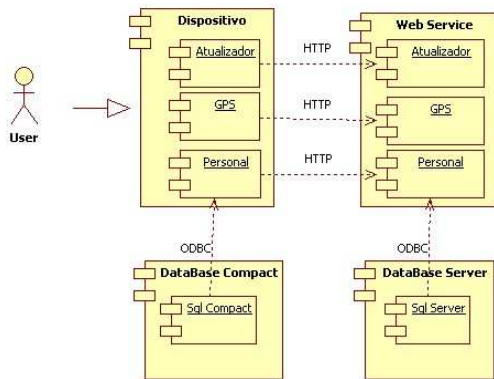


Fig. 4. Diagrama de Componentes Personal_Movie

não às suas necessidades ou desejos. Esta informação alimenta o sistema como uma nova informação, aumentando a precisão de futuras sugestões (figura 4).

O motor de recomendação aplica a técnica FBIC, a fim de coletar as informações sobre filmes que estão em cartaz no cinema, e após isso aplica a FBC para categorização das informações sobre filmes e realiza o armazenamento dessas informações na base de dados usando o SGBD SQL Server 2008 R2 [16].

Para finalizar o processo de geração da recomendação, o



Fig. 5. Seleção de Filmes

protótipo utiliza a técnica de recomendação FC para calcular a similaridade entre itens que foram avaliados pelo usuário-alvo utilizando a correlação de Pearson [4].

Caso o usuário deseje receber recomendações mais específicas, basta que o mesmo selecione a opção "P" (Personalidade) (figura 5) disponível nas interfaces de "Recomendação e Programação", e ele será direcionado para a interface de personalidade. Nela os itens serão expostos levando-se em consideração os traços de personalidade do usuário. Serão preditos itens de acordo com a similaridade da personalidade aplicando a FBP entre usuários, que, segundo Nunes e Cazella [27] pode vir a reduzir o problema do *cold-start*.

Durante as primeiras interações com o sistema, serão preditos os filmes que possuam horário de exibição mais próximo ao horário atual, uma vez que o usuário ainda não teria tido oportunidade de interagir com nenhum item, visando também diminuir o problema do *cold-start*.

Cada avaliação realizada pelo usuário via Personal_Movie é enviada para o servidor e armazenada no sistema, o que garante que, a cada vez que o algoritmo de recomendação for

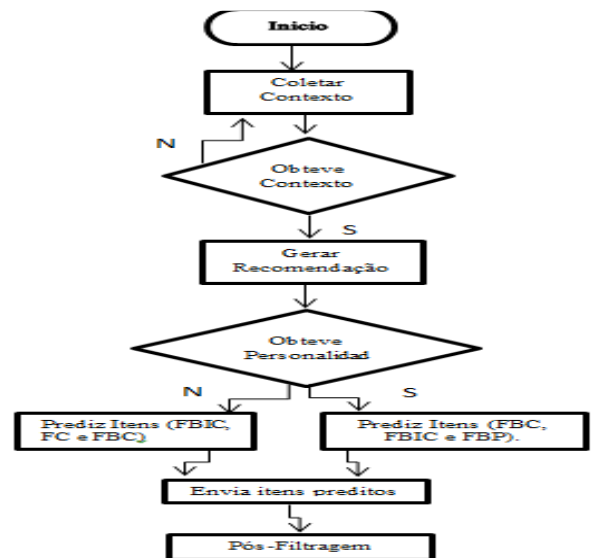


Fig. 6. Fluxograma Personal_Movie

executado novamente por qualquer usuário do sistema, estas informações transmitidas serão processadas e poderão gerar recomendações diferentes das anteriormente criadas.

Como se pode perceber a partir da discussão e ilustrado pela figura 6, o fluxo seguido pelo protótipo utiliza-se da técnica de FH para prever itens com maior possibilidade de assertividade na recomendação. Outra característica que o diferencia dos demais sistemas explicitadas na seção III é a disponibilização desses itens preditos através de dispositivo móvel, possibilitando aos usuários do serviço receber recomendações de maneira rápida e eficaz, podendo auxiliar o processo natural de escolha.

V. EXPERIMENTO

Como descrito, esse experimento é um *testbed* de como a tecnologia proposta por esse trabalho pode personalizar de forma eficiente a oferta de informação, produtos e serviços aos turistas dos megaeventos dos próximos anos.

O *testbed* mede a percepção dos usuários em relação à recomendação de filmes usando o Personal_Movie.

A. Hipótese de pesquisa

A seguinte hipótese de pesquisa foi levantada para a realização do experimento: O Personal_Movie pode extrair informações contextuais e utilizá-las em conjunto com os traços de personalidade para geração de recomendação baseada em FBP e FBIC.

B. Perfil da amostra

Esta experimentação contou com a participação de vinte e




Fig. 7. Perfil da Amostra

seis indivíduos, alunos dos Cursos de Computação da Universidade Federal de Sergipe.

O conjunto de dados obtido representa os hábitos de 26 usuários que assistiram filmes durante o período do experimento que foi de 10 de abril a 8 de maio de 2012.

Foi realizado um mapeamento da amostra coletada, conforme a figura 7, que **expressa** à faixa etária da amostra em relação ao sexo, objetivando fornecer subsídios para posterior análise de dados e de um futuro mapeamento de itens consumidos por faixa etária/sexo.

C. Metodologia de trabalho

Objetivando avaliar o Personal_Movie foi criada uma aplicação móvel utilizando dados do GPS para coletar o contexto no qual o usuário estivesse inserido, tornando viável a realização do experimento com uma população qualquer.

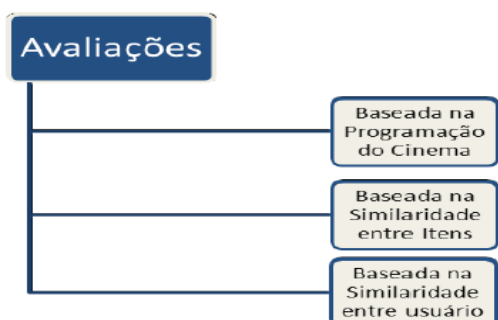


Fig. 8. Atividades Disponibilizadas para Avaliação do Protótipo

Para execução, a pesquisa foi disponibilizada em “um endereço web”, onde são demonstrados os passos para instalação do aplicativo no dispositivo, bem como o manual do sistema contendo informações detalhadas sobre como utilizar o aplicativo de forma correta.

O primeiro passo para realização do experimento correspondeu ao mapeamento dos traços de personalidade de cada usuário no *Inventory* [29] em um processo de coleta explícita de dados. Em seguida, foi feita a importação dos resultados dos testes de personalidade para o Personal_Movie, juntamente com as informações complementares obtidas no cadastro realizado pelos usuários como e-mail, senha, idade, etc.

Após essa etapa de coleta, os usuários do experimento acessaram o Personal_Movie e nele foram disponibilizadas três atividades avaliativas sobre filmes, conforme a Figura 8.

Na avaliação baseada em similaridade entre itens foram geradas recomendação utilizando as técnicas: FC, FBC e FBIC, já na Baseada na Similaridade entre usuário foi gerada recomendação de filmes através das técnicas: FBC, FBIC e FBP.

D. Métricas de avaliação

A métrica de Erro Absoluto Médio (*Mean Absolute Error*) foi aplicada nas duas formas de avaliação tradicionais baseadas em FC e a FBAP, conforme fórmula abaixo [13] [40].

$$MAE = \frac{\sum_{i=1}^N (r_i - \hat{r}_i)}{N} \quad (1)$$

Na aplicação da precisão, os *feedbacks* fornecidos pela amostra, foram convertidos para uma escala binária, sendo as de [3-5] como “relevante” e as notas de [1-2] classificadas como “não relevantes”.

E. Resultados

Foram avaliados 42 itens dentre as três interfaces propostas.

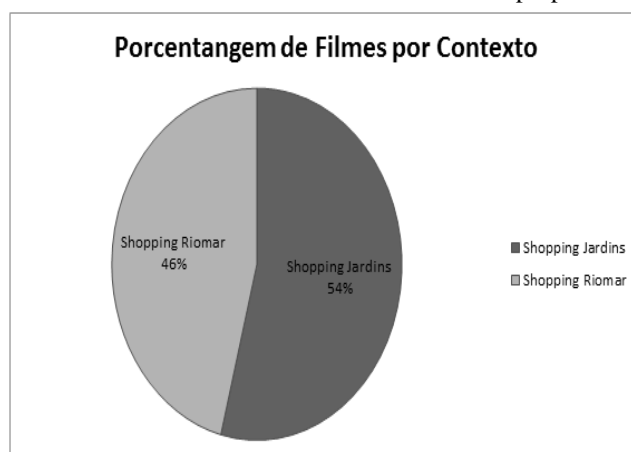


Fig. 9. Contextos por filmes

Durante o período para avaliação do software foram coletados 46 filmes em contextos distintos, tendo assim uma esparcialidade na base de dados considerada satisfatória, pois apenas 4 dos 46 itens não foram avaliados (9,52% na base de

dados).

Os 46 filmes foram coletados em contextos distintos. Dos




Fig. 10. Frequência de visita da amostra em cinemas

46 itens coletados, 21 (46%) foram coletados em um cinema (Cinemark Alfa) localizado no Shopping Alfa e 25 (54%) no cinema (Cinemark Beta) localizado no Shopping Beta, ambos localizados na cidade de Cidade-UF, conforme ilustra a figura 9.

A figura 10 ilustra a frequência com que os usuários visitaram determinado shopping.

Dos 71 filmes que estavam em cartaz em toda a rede Cinemark do Brasil durante o período da pesquisa, apenas 46 deles estavam disponíveis nos contextos coletados, ou seja, FBIC filtrou 25 itens que não estavam disponíveis aos contextos coletados (100% de eficiência), subtraindo assim

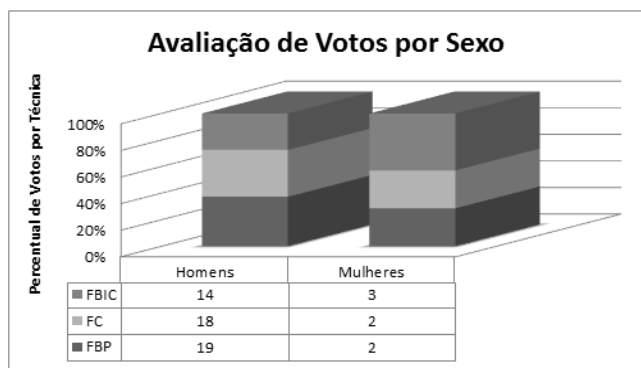


Fig. 11. Avaliação de itens por tipo de técnica

35% de itens que não se adequavam ao contexto do usuário e obtendo uma eficiência 14% superior no direcionamento de informações contextuais, caso não fosse aplicada a FBIC apenas 75% dos itens disponíveis no período se adequariam ao contexto.

A figura 11 ilustra a quantidade de itens avaliados por tipo de técnica (FBP, FC, FBIC) e sexo, disponibilizada pelo protótipo, tomando como base a amostra coletada o gráfico (figura 11) pode-se visualizar que o público feminino tem uma maior tendência ao uso da funcionalidade de ofertas pelo protótipo, porém essa afirmação não pode ser conclusiva devida à pequena abrangência dos testes realizados.

Entretanto, isto pode ser um indício de que o público feminino pode vir a utilizar mais as funcionalidades disponibilizadas pelos aplicativos, o que pode ser confirmado em estudos futuros.

No processo de avaliação do experimento, foram avaliados três algoritmos: FC (solução clássica de filtragem




Fig. 12. Comparação entre as técnicas tratadas no Personal_Movie

colaborativa) FBIC e a FBP.

Após os usuários terem realizado todos os passos do experimento, os dados do mesmo foram então processados. Diante disso, foram calculados o MAE e a precisão de ambos os algoritmos, como pode ser visto na Figura 12.

Os valores coletados corroboram que a assertividade do sistema utilizando a FBP apresentou-se melhor que a FC e a FBIC. O MAE apresentou-se 9% inferior e a precisão 10% maior na aplicando a FBP em relação à FC. Esta variação, apresentada na figura12, representa apenas a diferença obtida no experimento, devido não ser o foco deste trabalho, mensurar superioridade de recomendação, porém os dados podem ser utilizados para posteriores análises mais detalhada.

F. Discussão

Apesar de não ser o objetivo deste trabalho provar superioridade da qualidade das recomendações geradas pelo trabalho, foi possível observar que o Personal_Movie aplicando a FBP na recomendação obteve uma precisão de 10% e MAE de 9% inferior a FC (abordagem tradicional) na amostra de usuários selecionada por conveniência, esta diferença entre as técnicas pode atribuir ao uso da FBIC que comprovadamente aplicadas às outras técnicas aumentam a sua eficiência, gerando assim melhores recomendações. Através da aplicação da FBIC, foi possível subtrair 35% dos itens que não se adequavam ao contexto atual dos usuários.

Os dados apresentados mostram uma melhoria da recomendação de itens, através da aplicação da FBIC em conjunto com as técnicas abordadas por este trabalho (FC e FBP), porém esses resultados não podem ser tomados como base para afirmação de superioridade de nenhuma recomendação gerada por este trabalho, entretanto os dados podem dar subsídios para análises posteriores.

VI. CONCLUSÕES

Nos próximos anos, o Brasil sediará a Copa do Mundo, os Jogos Olímpicos e os Jogos Paraolímpicos e com o transcorrer desses eventos surge uma demanda maior por informações personalizadas sobre as atrações ofertadas pelo país, como por exemplo: filmes. Diante desse contexto, o protótipo mostra-se relevante e possui potencial de levar informações personalizadas aos turistas *in loco*.

Com o direcionamento de informações personalizadas para os turistas, espera-se que eles fiquem satisfeitos com a qualidade dos serviços ofertados, aumentando a probabilidade de que eles consumam produto, serviços nacionais, aquecendo assim a economia, bem como fornecendo subsídios para que elas obtenham uma imagem positiva do país e adquiram o desejo de voltar a visitá-lo.

A. Trabalhos Futuros

Com os resultados obtidos, foi possível verificar o potencial do Personal_Movie em prover recomendações personalizadas e eficientes ao seu público-alvo. Como trabalho futuro pretende-se tratar de questões que acreditamos ser também importantes para os megaeventos, como (i) aplicação de técnicas para recomendação de itens em grupo; (ii) criação de uma interface gráfica personalizada para o usuário a partir dos traços de personalidade extraídos do mesmo; (iii) disponibilização do software em outras plataformas móveis; (iv) mapeamento dos traços de personalidade de forma implícita através da avaliação dos filmes já assistidos pelo usuário; (v) análise de requisitos para garantia de escalabilidade pelo sistema (vi) verificação dos dados em populações maiores para melhor compreensão estatística dos resultados obtidos.

VII. BIBLIOGRAFIA

- [1] Adomavicius, G.; Tuzhilin, A. 2005. Toward the Next Generation of Recommender Systems: A Survey of the State-of-the-Art and Possible Extensions. In: IEEE Transactions on Knowledge and Data Engineering. Los Alamitos, p. 734-749.
- [2] Adomavicius, G.; Tuzhilin, Alexander. 2011. Context-Aware Recommender Systems. In: RICCI, Francesco et al. Recommender Systems Handbook. Nova York: Springer. cap. 7, p. 217-253.
- [3] Adomavicius, G.; Sankaranarayan, R.; Shahana Sen; Tuzhilin, A. 2005. Incorporating contextual information in recommender systems using a multidimensional approach. In: ACM Transactions on Information Systems. Nova York, p. 103-145.
- [4] Cazella, S. C.; Nunes, M. A. S. N.; Reategui, E. B. 2010. A Ciência do Palpite: Estado da Arte em Sistemas de Recomendação. In: Jornada de Atualização de Informática – JAI 2010 – CSBC. Rio de Janeiro: PUC RIO, v. 1, p. 161-216.
- [5] Caraciolo, M. 2011. Futuro dos Sistemas de Recomendação: Contexto e Mobilidade. Disponível em <<http://www.mobideia.com/2011/09/futuro-dos-sistemas-de-recomendacao.html>>. Acessado em 05/02/2012.
- [6] Dhrosattha. 2009. Predictive algorithm and what's so great about the NetflixPriz., Disponível em <<http://sendy82.wordpress.com/2009/09/22/predictive-algorithm-and-whats-so-great-about-the-netflix-prize/>>. Acesso em 07/02/2012.
- [7] ERL, Thomas. 2005. Service-Oriented Architecture. Concepts, Technology, and Desing. Indiana, Estados Unidos: Prentice Hall.
- [8] Fundação Getúlio Vargas – FGV. 2010. “Futebol e Desenvolvimento Econômico-Social”, Entrevista com Franz Beckenbauer, *Cadernos FGV Projetos*, 5 (13), 10-22.
- [9] Gadanho, S. C.; Lhuillier, N. 2007. Addressing uncertainty in implicit preferences. In: RECSYS '07: ACM Conference on Recommendation Systems. Minneapolis, p. 97-104.
- [10] GAMA, Erich, Richard Helm, Ralph Johnson, John Vlissides. 1995. Design Patterns: Elements of Reusable Object-Oriented Software. Addison-Wesley.
- [11] González, Gustavo et al. Embedding Emotional Context in Recommender Systems. In: IEEE 23rd International Conference on Data Engineering Workshop, 2007, Istanbul, p. 845-852.
- [12] Google. 2012. Android Developers. Disponível em <<http://developer.android.com>>. Acessado em 10/12/2011.
- [13] Hu, R; Pu, P. 2011. Enhancing collaborative filtering systems with personality information. In *Proceedings of the fifth ACM conference on Recommender systems* (RecSys '11). ACM, New York, NY, USA, 197-204
- [14] Idg Now, 2011. IG lança rede social focada em cinema. Disponível em < <http://idgnow.uol.com.br/internet/2010/10/20/ig-lanca-rede-social-focada-em-cinema/>>. Acessado em 14/01/2012.
- [15] IMDB, 2012. Disponível em <<http://www.imdb.com/>>. Acessado em <07/02/2012>.
- [16] Improving Performance with SQL Server 2008 Indexed View. Disponível em: [http://msdn.microsoft.com/en-us/library/dd171921\(v=sql.100\).aspx](http://msdn.microsoft.com/en-us/library/dd171921(v=sql.100).aspx). Acessado em 13/05/2012.
- [17] JINNI. 2012. Find movies, TV shows matching your taste & watch online. Disponível em <<http://www.jinni.com/>>. Acessado em 05/02/2012.
- [18] Lawler, Nicole. 2011. The Movie Experience gets more social with the smartlivingroom.com. Disponível em http://www.digitas.com/press/The_movie_experience_gets_more_social.pdf>. Acessado em 15/12/2012.
- [19] Likert, Rensis. A Technique for the Measurement of Attitudes, 1932. Archives of Psychology 140: pp. 1-55.
- [20] Loeb, S.; Terry, D. 1992. Information Filtering. Communications of ACM, New York, v.35, n.12, p.26.
- [21] Ministério do Turismo. 2011. Pesquisa World Cup – Turistas. Disponível em http://www.copa2014.turismo.gov.br/export/sites/default/copa/pesquisas/Resumo_Pesquisa_FGV.pdf
- [22] Morado, Denise et al. 2008. GESTÃO ESTRATÉGICA DA INFORMAÇÃO: a distribuição da informação e do conhecimento. Disponível em <http://www.arquivar.com.br/espaco_profissional/sala_leitura/artigos/gestao_estrategica_info.pdf/view?searchterm=None>. Acessado em 05/02/2012.
- [23] MovieLens, 2012. Disponível em <<http://movielens.umn.edu/>>. Acessado em <07/02/2012>.
- [24] Nunes, Maria A. S. N. 2008. Recommender Systems based on Personality Traits. Tese. Universidade Montpellier 2, Montpellier.
- [25] Nunes, M. A. S. N.; Cerri, Stefano A.; Blanc, N. 2008. Towards User Psychological Profile. In: VIII Simpósio Brasileiro de Fatores Humanos em Sistemas Computacionais, 2008, Porto Alegre. IHC 2008. ACM, New York : Sociedade Brasileira da Computação, 2008. v. 1. p. 196-203.
- [26] Nunes, M. A. S. N.; Moraes, D. B.; Reinert, D. 2010. Personality Inventory - PV 1.0 (Portuguese Version). Instituto Nacional de Propriedade Industrial. (software register nº INPI-12093-0).
- [27] Nunes, M. A. S. N.; Cazella, S. C. 2012. O que sua Personalidade revela? Fidelizando clientes web através de Sistemas de Recomendação e Traços de Personalidade. In: Patricia Vilain e Valter

- Roesler. (Org.). WEBMEDIA: Tópicos em Banco de Dados e Multimídia e Web. Porto Alegre: SBC, v. 1, p. 91-122.
- [28] Nunes, M. A. S. N., Bezerra, J. S., Oliveira, A. A. 2010. Estendendo o conhecimento afetivo da EmotionML. In *Proceedings of the IX Symposium on Human Factors in Computing Systems (IHC '10)*. Brazilian Computer Society, Porto Alegre, Brazil, 197-200.
- [29] Personality Inventory. Disponível em: <<http://www.personality-research.com/>>. Acesso em 12/01/2012.
- [30] Resnick, P.; Varian H. R. 1997. Recommender systems. *Commun. ACM* 40, 3 (March 1997), 56-58. <http://doi.acm.org/10.1145/245108.245121>
- [31] Ricci, F.; Rokach, L.; Shapira, B.; Kantor, P.B. 2011. *Recommender Systems Handbook 1st Edition.. XXIX*, 842 p. 20 illus.
- [32] Sommerville, Ian. 2007. *Engenharia de Software. 8ª Edição*. São Paulo: Addison-Wesley.
- [33] Trevisan, L. F., Cazella S. C., Nunes, M. A. S. N. 2011. Aplicando Traços de Personalidade e Contextos em Sistemas de Recomendação para TV Digital: um facilitador do processo de ensino-aprendizagem.
- [34] Vieira, V.; Souza, D.; Salgado, A.C.; Tedesco, P. 2006. Uso e Representação de Contexto em Sistemas de Computacionais, Minicurso apresentado no Simpósio de Fatores Humanos em Sistemas Computacionais (IHC 2006), Natal, Brasil.
- [35] Vieira, V., Tedesco, P., Salgado, A. C. 2009. "A Process for the Design of Context-Sensitive Systems", In: Proc. of the 13th International Conference on Computer Supported Cooperative Work in Design (CSCWD'09), pp. 143-148, Santiago, Chile.
- [36] Whattorent, 2012. Disponível em <<http://www.whattorent.com.>> Acessado em 07/02/2012.
- [37] Differentially Private Recommender Systems: Building Privacy into the Netflix Prize Contenders. <http://research.microsoft.com/pubs/80511/NetflixPrivacy.pdf> Acessado em 01/10/2012
- [38] Konstan, Joseph A.; Riedl John. Recommender systems: from algorithms to user experience. Disponível em : <<http://www.grouplens.org/system/files/algorithmstouserexperience.pdf>. Acessado em 01/10/2012>.
- [39] Good, Nathaniel et al. Combining collaborative filtering with personal agents for better recommendations. In: Proceedings of AAAI-99, AAAI Press. p. 439-446, 1999.
- [40] Herlocker, Jonathan I. Understanding and Improving Automated Collaborative Filtering Systems. Tese. Universidade de Minnesota, Minnesota, 2000.
- [41] Anderson Chris, 2011. Recommender systems for e-shops. Disponível em: <http://www.few.vu.nl/en/Images/werkstuk-hiralall_tcm39-202691.pdf>. Acessado em 04/10/2012.
- [42] Hu, R; Pu, P. 2009. A Comparative User Study on Rating vs. Personality Quiz based Preference Elicitation Methods. Disponível em: http://hci.epfl.ch/publications/2009/Hu_IUI_2009.pdf. Acesso em: 05/10/2012.
- [43] Perez, Sarah, 2011. Local Recommendations App Alfred Now Does Group Recommendations. Disponível em <http://techcrunch.com/2011/10/26/local-recommendations-app-alfred-now-does-group-recommendations/>>
- [44] Brainstorm, Fortune. 2011. Clever Sense Curates the Real World to Match Consumers with Places and. Disponível em : http://static.googleusercontent.com/external_content/untrusted_dlcp/hecleversense.com/en/pdfs/cleversense_pressrelease_07192011.pdf
- [45] John, Oliver p. E Sivastava, Sanjay. The big five trait taxonomy: History, measurement, and theoretical perspectives. In: *Handbook of Personality: Theory and Research*. New York: Guilford, 1999, p. 102-138.
- [46] JOHN, Oliver P. e SRIVASTAVA, Sanjay. The big five trait taxonomy: History, measurement, and theoretical perspectives. In: *Handbook of Personality: Theory and Research*. New York: Guilford, 1999, p. 102-138.