

# EXPLICAÇÃO DE RECOMENDAÇÕES COM DIVERSIFICAÇÃO: UMA REVISÃO BIBLIOGRÁFICA

Alessandro da Silveira Dias, Leandro Krug Wives,  
Guilherme Medeiros Machado, Gabriel Machado Lunardi

Instituto de Informática – Universidade Federal do Rio Grande do Sul (UFRGS)  
Porto Alegre, RS – Brazil

{alessandro.dias, leandro.wives, guimmachado, gmlunardi}@inf.ufrgs.br

**Resumo:** *Esse artigo apresenta o resultado de uma revisão bibliográfica sobre explicação de recomendação com diversificação. Constatou-se com base nela que nenhuma pesquisa propôs ainda estudar como gerar explicação de recomendação com diversificação. Foram encontrados apenas trabalhos que indicam a necessidade de haver explicação de recomendação com diversificação. A partir dessa constatação de necessidade de pesquisa propõe-se, como trabalho futuro, investigar e desenvolver uma abordagem de explicação de recomendação com diversificação. Essa abordagem terá que gerar explicações que sejam interpretáveis e persuasivas de modelos complexos de recomendação baseados em algoritmos de aprendizagem de máquina. Para avaliação experimental da abordagem de explicação de recomendação há possibilidade, dentro do grupo de pesquisa de Sistemas de Informação da UFRGS, de aplicar e avaliar essa abordagem de explicação no domínio de Cidades Inteligentes.*

**Abstract:** *This paper presents the result of a bibliographic review on explanation of recommendation with diversification. It was found that there is no research proposed about how to generate explanation of recommendation with diversification yet. There are only researches that indicate the need for explanation of recommendation with diversification. From this finding of research need, it is proposed, as future work, to investigate and develop a explanation approach for recommendation with diversification. This approach will have to generate explanations that are interpretable and persuasive of complex recommendation models based on machine learning algorithms. For the experimental evaluation of the explanation approach of recommendation with diversification, it is possible within the UFRGS Information Systems research group, to apply and evaluate this explanation approach in the domain of Smart Cities.*

## 1. Introdução

Os primeiros Sistemas de Recomendação (SR) foram desenvolvidos na década de 1990 com o intuito de auxiliar usuários a encontrarem itens relevantes em meio a grandes conjuntos de itens (RESNICK et al., 1994). Mais tarde, Eric Schmidt, CEO da Google, apontou que as técnicas de recomendação têm sido empregadas em praticamente todos os serviços online, incluindo motores de busca, redes sociais, plataformas de streaming

de mídia, etc. (HOLMAN; JENKINS, 2010). Sendo assim, considerando que a maioria das pessoas, atualmente, experiencia a Web através dos serviços citados, os SR tornaram-se onipresentes, trazendo benefícios como a diminuição da sobrecarga de informação sobre o usuário, o aumento da receita de fornecedores, a fidelização de clientes, o apoio à tomada de decisão, dentre outros (JANNACH; ADOMAVICIUS, 2016).

Além disso, a grande maioria dos SR propostos foca na acurácia (precisão) de recomendação, de forma mais específica, prima maximizar a acurácia da recomendação tanto quanto possível, com base em preferências passadas do usuário. Quanto maior a acurácia, melhor os itens recomendados atendem à necessidade de informação do usuário.

Essa ênfase em acurácia tem um efeito indesejável: como as recomendações são produzidas com base na experiência passada do usuário, elas costumam ser muito similares entre si e sem novidades; além disso, há o indesejável efeito de “bolha de filtro” (PARISER, 2012), que se refere ao isolamento do usuário em relação a uma diversidade de conteúdos e experiências, tornando-o menos propenso a descobrir e aprender coisas novas.

Recentemente, Jannach e Adomavicius (2016) fizeram uma análise do estado da arte dos últimos dois anos, analisando os artigos da mais específica e notória conferência da área, a ACM RecSys, na qual constataram que 85% dos artigos utilizam pelo menos uma métrica de avaliação de acurácia sobre a recomendação. Apenas 20% dos trabalhos buscam melhorar algoritmos em termos de novidade, diversidade, e outras métricas de qualidade.

A **novidade** indica o quão bem o SR recomenda itens desconhecidos para os usuários. Tipicamente é medida sobre listas de itens recomendados, mas pode ser medida entre itens recomendados isoladamente considerando-se o quão diferente o item é dos itens recomendados no passado. A **diversidade**, tipicamente, indica o quão diferentes são entre si os itens recomendados dentro de uma lista de itens recomendados (CASTELLS *et al.*, 2015).

Porém, já se constatou que recomendações com alta acurácia não são necessariamente úteis ao usuário (McNEE *et al.* 2006): o valor real se encontra na habilidade em recomendar itens relevantes que não são fáceis de serem descobertos pelos usuários, ou seja, que a recomendação apresente novidade e diversidade. Além disso, constatou-se também que ao aumentar-se a diversidade diminui-se a acurácia de recomendação e vice-versa (RICCI *et al.*, 2011).

Assim, pesquisas recentes têm buscado criar soluções que encontrem um equilíbrio adequado entre precisão e diversidade, por exemplo, Willemsen *et al.* (2017), ou entre precisão, diversidade e novidade, por exemplo Ribeiro *et al.* (2014). Essas pesquisas têm focado em gerar listas de itens recomendados que reflitam essas duas, ou três, medidas de interesse simultaneamente, *dentro* da lista.

Uma vez conceituadas a acurácia de recomendação, a diversidade e a novidade é possível, então, apresentar a seguinte definição: uma abordagem de **recomendação com diversificação** é aquela que estabelece um equilíbrio adequado entre acurácia e diversidade, ou entre acurácia, diversidade e novidade. A maioria das abordagens de diversificação foca em equilibrar apenas acurácia e diversidade; algumas, mais recentes, focam em equilibrar acurácia, diversidade e novidade.

Nesse contexto surge um grande problema: o usuário pode não entender o porquê de alguns itens serem recomendados. Por exemplo, considere um usuário (um cidadão em uma cidade inteligente) que está querendo ir de carro até um ponto de sua cidade e recebe do sistema do carro uma lista de caminhos possíveis, de onde está até o ponto desejado. Ao analisar a lista ele pode perguntar para si mesmo: *“por que o sistema recomendou para eu ir por esse caminho X, se eu gosto e costume ir para aquela região sempre por esse outro caminho Y?”*.

Esse problema está relacionado com a pesquisa de Castagnos *et al.* (2013). Nesse trabalho os autores mostram um estudo que relaciona acurácia e diversidade de recomendação, e os resultados indicam que explicações de recomendação podem ser necessárias porque os usuários podem “não conseguir ver o relacionamento entre suas preferências informadas e os itens apresentados na recomendação”.

Outra propriedade para avaliar SR, além da acurácia, diversidade e novidade, é a serendipidade. A **serendipidade** é uma visão mais forte da novidade. Herlocker *et al.* (2004) esclarecem a diferença entre elas. A novidade está relacionada com itens que o usuário não conhece ou nunca viu antes. Já a serendipidade é uma visão mais forte de novidade e é definida como um item novo e inesperado ou não óbvio. Uma recomendação óbvia refere-se a um item que o usuário poderia encontrar por conta própria, sem o auxílio do sistema de recomendação, por exemplo, um item altamente popular ou um item muito semelhante ao que ele já viu (por exemplo, um livro de um autor que ele já conhece e leu muitos livros). Em poucas palavras, um item pode ser novo para o usuário, mas não surpreendente.

Nesse contexto, onde o usuário recebe recomendações de itens novos e inesperados ou não óbvio (serendipidade), ele pode não aceitar os itens recomendados. Por exemplo, o usuário na cidade inteligente do exemplo citado pode perguntar para si mesmo: *“por que o sistema recomendou para mim o caminho Z? não faz sentido, vou ter que fazer um percurso mais longo, que eu nem sabia que existia. Acho que esse sistema tem problema!”*.

Dessa forma, explicações de recomendações podem ajudar a manter a confiança do usuário no sistema e o persuadir a sair da sua “bolha de filtro” que ele está acostumado, a descobrir e aprender coisas novas. Voltando ao exemplo citado, a explicação dessa recomendação é crucial para manter a confiança do usuário no sistema e a explicação pode ajudar o usuário a aceitar a recomendação, o que pode possibilitar a ele ter uma experiência turística maximizada.

Conceitualmente **explicações de recomendação** são informações extras que acompanham a recomendação, que ajudam o usuário a entender as qualidades de um item recomendado de forma a ajudá-lo a decidir se o item é relevante ou não (TINTAREV; MASTHOFF, 2015). Por exemplo, no site da Amazon, quando o usuário acessa a página de um produto aparece uma lista de produtos recomendados (Figura 1, da Seção 2.3). Acima dessa lista aparece um *label* com a seguinte explicação de recomendação: “Clientes que compraram esse item também compraram...”.

Além disso, essa explicação ajuda o usuário a entender como o sistema funciona (ela indica ao usuário que essa recomendação é baseada no comportamento de uma comunidade de usuários), ela serve para persuadir o usuário a comprar e experimentar outros itens, e, em uma visão global, aumentar sua satisfação com o sistema.

Conforme constatado, explicações de recomendação podem ter diferentes objetivos. Tintarev e Masthoff (2007) define esses objetos: *Transparência*: explicar

como o sistema funciona, como gerou a recomendação; *Confiança*: aumentar a confiança dos usuários no sistema; *Persuasão*: convencer os usuários a experimentar ou comprar um item; *Eficiência*: ajudar os usuários a tomar decisões mais rapidamente; *Satisfação*: aumentar a satisfação do usuário; entre outros. Além disso, há objetivos inter-relacionados, por exemplo, aumento na Transparência pode gerar aumento na Confiança; Persuasão demais pode gerar diminuição de Satisfação.

Portanto, **a falta de explicação de recomendação com diversificação** pode ocasionar sérios problemas, em especial, falta de confiança do usuário no sistema (e subsequente perda de usuários do sistema), aumento do tempo dos usuários no processo de escolha de itens, e diminuição da satisfação dos usuários com o sistema.

Com base nesses fatos, realizamos uma revisão bibliográfica sobre os repositórios ACM Digital Library, IEEE Explorer, ScienceDirect e Springer Link com o objetivo de descobrir como é feita a explicação de recomendação com diversificação. O processo de revisão realizado e os resultados obtidos são apresentados na Seção 3.

Nenhuma pesquisa propôs estudar a explicação de recomendação com diversificação até o momento. Foram encontrados apenas trabalhos que indicam a necessidade de haver explicação de recomendação com diversificação. Tais trabalhos, junto com trabalhos relevantes encontrados durante a revisão, são apresentados na Seção 3.1

As seções seguintes desse artigo estão organizadas da seguinte forma: na Seção 2, apresentamos diversos conceitos necessários para o entendimento de recomendação com diversificação e de explicação de recomendação; na Seção 3, conforme já citado, apresentamos a revisão bibliográfica realizada; e na Seção 4 apresentamos as considerações finais e trabalho futuro.

## **2. Fundamentação Conceitual**

A fundamentação conceitual apresentada a seguir apresenta os conceitos-chave de sistemas de recomendação, de diversificação e novidade em recomendação, e de explicação de recomendação.

### **2.1 Sistemas de Recomendação**

Sistemas de recomendação tradicionais são definidos de uma forma genérica por Ricci et al. (2011) como técnicas e ferramentas de software usadas para prover sugestões de itens a serem utilizados por um usuário. Essa definição mostra que pelo menos duas dimensões de informação são utilizadas nos sistemas de recomendação tradicionais, são elas, o usuário e o item a ser recomendado. Na abordagem mais comum desse tipo de sistema, conhecida como filtragem colaborativa, as avaliações sobre itens dadas por um usuário são utilizadas com o intuito de gerar recomendações a outro usuário que tenha preferências semelhantes.

Formalmente, o problema de recomendação é definido como sendo o de encontrar uma função que tenha como saída um *score* para cada item tendo como entrada informações sobre perfil de usuário e sua situação contextual, informações sobre o "conteúdo" do item e informações sobre padrões de preferência de uma comunidade de usuários (ADOMAVICIUS; TUZHILIN, 2005). Esse *score* é utilizado ou para indicar até que ponto o usuário alvo da recomendação vai gostar ou não gosta de um certo item, ou para gerar uma lista de itens recomendados ao usuário.

Herlocker *et al.* (2004) identificaram as principais tarefas realizadas pelo usuário que podem ser auxiliadas por um sistema de recomendação. As mais recorrentes delas são:

- **Anotação no contexto:** dado um determinado contexto, por exemplo, uma lista de itens, o sistema destaca alguns itens com base nas preferências de longo prazo do usuário. Um exemplo de sistema que utiliza esta abordagem é o *Tapestry* (GOLDBERG *et al.*, 1992), que foi o primeiro sistema de recomendação desenvolvido. O *Tapestry* recebia uma lista de *e-mail* corporativos e destacava aqueles que determinado usuário pudesse estar interessado.
- **Encontrar bons itens:** o sistema provê interfaces que sugerem itens específicos a cada usuário, estes itens são classificados em uma lista e o sistema ainda mostra previsões de quanto o usuário gostaria de cada item. Um exemplo de sistema que utilizaria essa abordagem seria um sistema de recomendação de filmes que, além de recomendá-los, ainda os classificaria com base na previsão da nota que o usuário daria a cada filme após assisti-lo.
- **Encontrar todos os itens bons:** a maioria dos sistemas de recomendação sugerem apenas alguns itens interessantes. Alguns usuários estão dispostos a receberem apenas alguns itens interessantes em troca do descarte de muitos itens não interessantes, evitando assim uma sobrecarga cognitiva na análise de muitos itens recomendados. Outros usuários, entretanto, têm interesse em analisar todos os itens interessantes e assim um desafio a este tipo de sistema é evitar falsos positivos. Um domínio que se beneficia deste tipo de abordagem é o domínio jurídico, muitas vezes advogados estão interessados em conhecer todas as possíveis brechas que um documento legal possa ter em relação à legislação vigente.
- **Recomendar sequências:** esta tarefa diferencia-se das anteriores, pois ao invés de recomendar um item por vez o sistema deve recomendar uma sequência de itens de interesse do usuário. Um exemplo de sistema que se encaixa nesta tarefa são os sistemas que recomendam *playlists* de músicas, outro exemplo de sistema é um recomendador de artigos científicos utilizados para ensinar sobre um determinado campo de estudo.

Paralelo a isso, são encontrados, na literatura, vários sistemas de recomendação que se propõem a auxiliar o cumprimento dessas tarefas. Ricci *et al.* (2015) propõem uma interessante classificação dos sistemas de recomendação baseando-se na técnica utilizada para recomendar itens:

- **Baseado em conteúdo:** o sistema aprende a recomendar itens similares aos que o usuário gostou no passado. Para isso, ele leva em conta características associadas aos itens comparados. Por exemplo, se o usuário classificou positivamente um filme de gênero de comédia, o sistema então aprenderá a recomendar outros filmes do mesmo gênero.
- **Baseado em filtragem colaborativa:** o usuário recebe recomendações de itens que outros usuários com gostos similares classificaram positivamente no passado. A similaridade de gostos de dois usuários é calculada com base na similaridade do histórico de classificação dos usuários.

- **Baseado em demografia:** o sistema recomenda itens baseando-se no perfil demográfico do usuário. Assume-se que diferentes recomendações devem ser geradas para diferentes nichos geográficos. Um exemplo comum de uso desta técnica é quando sites da Web direcionam seus usuários à páginas traduzidas para um idioma falado em seu país.
- **Baseado em conhecimento:** o sistema utiliza conhecimento específico de domínio a fim de corresponder características dos itens com necessidades e preferências do usuário ou em último caso, como o item pode ser útil a este. Para realizar essa correspondência, uma função de similaridade estima em quanto as necessidades do usuário correspondem às características do item e do usuário através de restrições. Em termos de conhecimento utilizado, ambas as estratégias são similares, requisitos do usuário são coletados; alternativas para requisitos inconsistentes são propostas a fim de evitar situações sem solução; e resultados são explicados. A principal diferença entre as estratégias é determinada através da maneira que é calculada a correspondência usuário-item. No primeiro caso é utilizada uma função de similaridade para tal e, no segundo caso, são utilizadas regras explícitas que relacionam o usuário e item com base no conhecimento prévio do domínio.
- **Baseado em comunidade:** o sistema recomenda itens com base na preferência dos amigos do usuário. Esse tipo de sistema tem se tornado de grande interesse de estudo ultimamente devido ao advento das redes sociais. É também conhecido por sistema de recomendação social já que considera o relacionamento do usuário com seus amigos para recomendar itens.
- **Sistemas híbridos:** combina duas ou mais técnicas mencionadas acima. Um sistema híbrido que combina as técnicas A e B tenta utilizar as vantagens de A para contornar as desvantagens de B. Por exemplo, sistemas que utilizam filtragem colaborativa tem problemas para recomendar itens novos, já que esses nunca foram classificados. Esse problema, entretanto, não limita uma abordagem baseada em conteúdo, pois essa considera apenas características intrínsecas do item a ser recomendado.
- **Sistemas sensíveis ao contexto:** o sistema incorpora informações de contexto no processo de recomendação. Por exemplo, um dado sistema pode gerar recomendação levando em conta o local, horário e companhia do usuário (ADOMAVICIUS; TUZHILIN, 2015).

## 2.2 Novidade e Diversidade em Recomendação

Os primeiros sistemas de recomendação foram criados há mais de duas décadas e, desde então, a maioria dos esforços de pesquisa e desenvolvimento na área de sistemas de recomendação tem focado na acurácia (precisão) de recomendação com base em preferências passadas do usuário. Quanto maior a acurácia, melhor os itens recomendados atendem à necessidade de informação do usuário.

Porém estudos que focam em aceitação e adoção de sistemas de recomendação por usuários mostraram que uma diferença de 10% na acurácia de recomendação não é percebida pelos usuários. Tais estudos ressaltam a influencia de fatores humanos na aceitação de tais sistemas. Esses fatores podem ser: a confiança dos usuários no sistema de recomendação, as explicações de recomendação fornecidas pelo sistema ou a necessidade de diversidade de recomendações (CASTAGNO *et al.*, 2014).

Nesse contexto, outras propriedades de sistemas de recomendação, além da acurácia de recomendação, têm sido empregadas para a avaliação de sistemas de recomendação, tais como, novidade e diversidade em recomendação.

Porém existe um *trade-off* entre acurácia de recomendação e diversidade: ao aumentar-se a diversidade diminui-se a acurácia de recomendação e vice-versa (RICCI *et al.*, 2011). Nesse sentido começaram a surgir abordagens de recomendação que buscam criar um balanceamento entre acurácia de recomendação e diversidade. Zeigler *et al* (2005) foi a primeira proposta com esse objetivo.

Em 2011, foi promovido o *1º Workshop on Novelty and Diversity in Recommender Systems*, dentro da conferência RecSys, a principal conferência da área de Sistemas de Recomendação. Nesse foram lançadas diferentes abordagens de recomendação que buscaram criar um balanceamento entre acurácia de recomendação e diversidade. Essas abordagens foram denominadas nesse *workshop* de métodos de *recomendação com diversificação* (CASTELLS *et al.*, 2011).

Em Ribeiro *et al.* (2014) a ideia de recomendação com diversificação é amplificada: nesse trabalho é lançado um sistema de recomendação capaz de realizar recomendações simultaneamente com acurácia, diversidade e novidade.

Assim, abordagens de recomendação que buscam incluir diversidade sem penalizar a acurácia de recomendação, ou incluir diversidade e novidade sem penalizar a acurácia de recomendação - criando um equilíbrio entre essas partes - são denominadas de **abordagens de recomendação com diversificação**.

De forma geral, recomendações com diversidade/novidade ajudam a aumentar o fluxo de informações entre o usuário e o sistema. A descoberta de novos itens leva ao *feedback* dos usuários em itens diversos/novos. Isso gera maior ganho de informação para o perfil do usuário do que o *feedback* de itens não-inovadores, ampliando o conhecimento sobre as preferências do usuário (LEMIRE; DOWNES; PAQUET, 2008).

A seguir são apresentadas definições de novidade e diversidade em recomendação. E, em seguida, são apresentadas exemplos de abordagens que fazem recomendação com diversificação.

### 2.2.1 Conceitos de Novidade e Diversidade em Recomendação

De forma geral, novidade geralmente se refere a diferença entre a experiência presente e a experiência passada do usuário, ao passo que diversidade se relaciona a diferenças internas dentro de partes de uma experiência (CASTELLS *et al.*, 2015).

A **novidade** indica o quão bem o SR recomenda itens desconhecidos para os usuários. Tipicamente é medida sobre listas de itens recomendados, mas pode ser medida entre itens recomendados isoladamente considerando-se o quão diferente o item é dos itens recomendados no passado (CASTELLS *et al.*, 2015).

A **diversidade**, tipicamente, indica o quão diferentes são entre si os itens recomendados dentro de uma lista de itens recomendados. Porém existem outras maneiras de medir diversidade, por exemplo, ela pode ser medida entre listas de itens recomendados ao usuário ao longo do tempo, ou pode ser medida uma diversidade global (ou agregada) envolvendo as listas de recomendação de todos os usuários do sistema (CASTELLS *et al.*, 2015). Essas diferentes maneiras de medir diversidade (e também novidade) indicam que elas podem ser medida em diferentes níveis.

Outro conceito importante é a serendipidade. A **serendipidade** é uma visão mais forte da novidade e é definida como um item novo e inesperado ou não óbvio; está relacionada com recomendações surpreendentes. Segundo Murakami *et al.* (2008) e Zhang *et al.* (2012), serendipidade é usada para exprimir novidade somada a uma resposta emocional positiva do usuário (ao receber uma recomendação surpreendente).

### 2.2.2 Exemplos de Abordagens de Recomendação com Diversificação

Ziegler *et al.* (2005) apresentam uma abordagem de diversificação, denominada pelos autores de “diversificação de tópico”, que se destina a equilibrar e diversificar listas de itens recomendados para refletir o espectro completo de interesses do usuário. O algoritmo de diversificação de tópicos considera como entrada uma lista de recomendação gerada por um SR tradicional (que foca em acurácia) e uma taxonomia (uma ontologia) obtida separadamente do dataset usado para calcular a recomendação. Nos experimentos foram recomendados livros e foi utilizada a taxonomia de livros da Amazon. O objetivo do algoritmo é reclassificar a lista de itens recomendados de entrada e obter uma lista final de itens recomendados diversificada. Além disso, os autores propõem uma métrica para o cálculo de diversidade denominada ILS (Intra-List Similarity).

Mais tarde, em Knijnenburg *et al.* (2012), os autores tentaram reproduzir em recomendação de filmes os resultados encontrados de Ziegler *et al.* (2005), e confirmaram tais resultados utilizando uma avaliação centrada no usuário, e não em uma métrica (avaliação quantitativa). Neste estudo, as listas de recomendação foram diversificados com base nas informações do gênero do filme.

Adomavicius e Kwon (2009) propõem métodos de reclassificação de itens para aumentar a diversidade agregada, mantendo níveis aceitáveis de precisão para os resultados da recomendação. Os autores explicam que os SR tradicionais oferecem a um usuário uma lista de itens recomendados de acordo com um critério de classificação. Tal critério classifica itens em ordem decrescente de acordo com a relevância/classificação prevista de cada item. No entanto, esse *ranking* é projetado para melhorar a precisão, mas não considera a diversidade. Então os autores propõem novos métodos de *ranking* que podem controlar as perdas de precisão: padrão, popularidade de item, valor de classificação reverso previsto, classificação média de item, absorção absoluta do item e absorção relativa do item.

Zhang, F. (2009) propõe um algoritmo de recomendação que seleciona vários vizinhos com base em confiança. O autor argumenta que a limitação das técnicas de diversificação pós-filtragem é que os itens candidatos podem não ser suficientemente diversos e, como consequência, o melhor subconjunto que pode ser selecionado por um algoritmo de filtragem também não será suficientemente diversificado. Nesses casos, o próprio algoritmo de SR deve ser aprimorado para gerar resultados diversos. O autor propõe uma estratégia de otimização gulosa de diversificação para selecionar um conjunto diversificado de usuários vizinhos em um algoritmo de filtragem colaborativa baseado em confiança. A função objetiva proposta tem a mesma estrutura que o MMR (*Maximal Marginal Relevance*), em que a relevância de um vizinho é interpretada como o valor de confiança e a diversidade é medida com métricas de similaridade de usuário tradicionais.

Said *et al.* (2012) propõe uma técnica de filtragem colaborativa de vizinhos mais recentes para aumentar a serendipidade (novidade mais forte) e a diversidade. Esta técnica recomenda itens que não gostam de usuários que são os menos parecidos com o



usuário alvo. Através de experimentos com o *dataset* MovieLens, os autores acham que seu método fornece maior diversidade em uma perda de precisão tolerável em comparação com a técnica de vizinhança mais tradicional.

Resumindo, Galway (2015) indica que podem ser identificadas duas grandes linhas de pesquisa que propõem soluções para o problema de diversificação nos SR. A primeira e a mais forte se concentra nas abordagens **pós-filtragem**. Essas abordagens recebem como entrada resultados de recomendação gerados por um algoritmo de SR tradicional e visam selecionar, dos itens candidatos, o melhor subconjunto que equilibra acurácia e diversidade (ou acurácia, diversidade e novidade) para gerar uma lista final de recomendação de itens. Os trabalhos Ziegler et al. (2005); Knijnenburg et al. (2012) e Adomavicius; Kwon (2009) pertencem a essa linha. A segunda linha de soluções tenta **aprimorar os algoritmos de SR atuais** para gerar recomendações de itens mais diversas. Os trabalhos Zhang, F. (2009) e Said et al. (2012) pertencem à essa linha.

### 2.3 Explicação de Recomendação

Nos últimos anos, houve um progresso significativo no campo da inteligência artificial e, em particular, no contexto da aprendizagem de máquina (*machine learning*). Técnicas baseadas em aprendizagem de máquina estão agora incorporadas em vários tipos de sistemas de *software*. Elas fornecem informação para tais sistemas, que variam desde apoio ao usuário na tomada de decisão, por exemplo, sob a forma de sistemas de recomendação, até à tomada de decisão totalmente automatizada, por exemplo, por algoritmos que definem preços de produtos/serviços de forma dinâmica. No futuro, espera-se um aumento constante desses sistemas de *software*, em particular porque mais tipos de dados tornar-se-ão disponíveis, por exemplo, com dispositivos conectados à Internet das Coisas, que podem ser aproveitados por algoritmos modernos de aprendizagem de máquina. Isso levanta novas questões a serem levadas em conta no desenvolvimento de sistemas inteligentes, como prestação de contas e ética (BANAVAR, 2016).

Um requisito chave para o sucesso e adoção prática de tais sistemas em muitos domínios é que os usuários devem ter confiança nos resultados gerados por tais sistemas (por exemplo, em recomendações ou decisões automatizadas feitas por sistemas inteligentes) ou pelo menos confiar que o resultado dado não segue um viés. (NUNES; JANNACH, 2017). Porém muitos sistemas funcionam como “caixas pretas”, não sendo transparentes sobre como chegam aos resultados que produzem e nem fornecem informações adicionais para que o usuário entenda o porquê do resultado (HERLOCKER *et al.*, 2000).

Essas informações adicionais fornecidas por sistemas inteligentes são chamadas de *explicações*. No contexto de sistemas de recomendação, uma **explicação de recomendação** é uma descrição, textual ou visual, que ajuda o usuário a entender as qualidades de um item recomendado de forma a ajudá-lo a decidir se o item é relevante ou não (TINTAREV; MASTHOFF, 2015).

Por exemplo, no site da Amazon (Figura 1), quando o usuário acessa a página de um produto, nesse caso um livro, aparece uma lista de produtos recomendados. Acima dessa lista aparece um *label* com a seguinte explicação de recomendação: “Clientes que compraram esse item também compraram”. Essa explicação ajuda o usuário a decidir se o item é relevante ou não. Além disso, (I) ela ajuda o usuário a entender como o sistema funciona (indica ao usuário que essa recomendação é baseada no comportamento de uma comunidade de usuários), (II) serve para persuadir o usuário a comprar e

experimentar outros itens, e, em uma visão global, (III) aumentar sua satisfação com o sistema.

Cientes que compraram este item também compraram



**Figura 1: Explicação de uma lista de itens recomendados em uma página do site da Amazon: “Clientes que compraram esse item também compraram”**

Ressalta-se que na literatura encontram-se outros usos da palavra explicação, como a explicação visual de saída de processos de mineração de dados, as quais são projetadas por cientistas de dados para entender a saída de algoritmos de recomendação/decisão (NUNES; JANNACH, 2017). Nesse estudo a explicação abordada é aquela orientada ao usuário final do sistema de recomendação, responsável pela decisão final.

Conforme constatado, explicações de recomendação podem ter diferentes objetivos. Tintarev e Masthoff (2007) descreve os diferentes objetivos de explicações de recomendação (Quadro 1). Eles podem ser inter-relacionados, por exemplo, aumento na Transparência pode gerar aumento na Confiança; Persuasão demais pode gerar diminuição de Satisfação.

**Quadro 1: Objetos de Explicação de Recomendação (TINTAREV; MASTHOFF, 2007)**

Objetivo	Definição
Transparência	Explicar como o sistema funciona, como gerou a recomendação
<i>Scrutability</i>	Permitir que os usuários que indiquem que o sistema está errado ao gerar a recomendação
Confiança	Aumentar a confiança dos usuários no sistema
Eficácia	Ajudar os usuários a tomar boas decisões ao escolher um item
Persuasão	Convencer os usuários a experimentar ou comprar um item
Eficiência	Ajudar os usuários a tomar decisões mais rapidamente
Satisfação	Aumentar a satisfação do usuário

### 2.3.1 Cenário Histórico da Área de Explicação em Sistemas de Software

A área de explicação surgiu na década de 1980, quando começaram a surgir os Sistemas Especialistas. Por exemplo, havia sistemas especialistas na área de medicina onde o sistema tinha que dar uma explicação sobre como chegou ao diagnóstico de uma determinada doença. Isso mostra que a explicação é um item fundamental confiança e para a aceitação desses sistemas pelos usuários. Porém as pesquisas em explicação em sistemas especialistas entraram em declínio nos anos 1990, por diferentes fatores, tais como: em muitos casos as explicações, que geralmente eram cadeias de regras, complexas de serem entendidas mesmo por especialistas; e a base de conhecimento de tais sistemas era limitada ao conhecimento do determinado conjunto de especialistas que a desenvolvia.

Na década de 2000 a área de explicação reviveu, por diferentes motivos, tais como: crescimento de bases de dados (com o crescimento da Web, muitos usuários começaram a usar sistemas e a contribuir com dados e informações); uso de modernos algoritmos de aprendizagem de máquina, para descobrir conhecimento de grandes massas de usuários, em vez de obter o conhecimento de pequenos grupos de especialistas (TINTAREV; MASTHOFF, 2015); e incorporação de sistemas de recomendação em vários serviços oferecidos por grandes empresas que operam sobre a Web, tais como Google e Amazon.

### 2.3.2 Conteúdo e Apresentação de Explicações de Recomendação

Nudes e Jannach (2017) analisam centenas de trabalhos na área de explicação (sistemas especialistas, sistemas baseados em conhecimento, sistemas de recomendação e sistemas de suporte à tomada de decisão) e indicam que o conteúdo apresentado em explicações pode ser organizado nos seguintes grupos e subgrupos:

- preferências de usuários e *inputs*: explicações que informam o porquê da recomendação com base em *inputs* e/ou preferências de usuário. Por exemplo, no subgrupo *preference match*: a explicação “filmes recomendados para você, porque você gosta de filmes de Ação e Artes Marciais” indica um *match* entre as preferências do usuário e metadados de filmes.
- Processo de tomada de decisão: explicações que contêm informações sobre o processo de inferência de um problema de domínio específico. Por exemplo, no subgrupo *inference and domain knowledge*: a explicação “Filmes recomendados para você com base nos que as pessoas mais similares a você gostaram” indica ao usuário que no processo de inferência foram descobertas pessoas com preferências similares ao do usuário.
- Informações de segundo plano e complementares: informações complementares à explicação dada. Por exemplo, no subgrupo *background data*: “dados derivados de processamentos de *posts* na rede social Facebook foram considerados no processo de decisão por inferência”.
- Alternativas e suas características: explicações que analisam as características entre as alternativas, por exemplo, as características dos itens recomendados. Por exemplo, no subgrupo *pros and cons*: “esse

filme é um filme Histórico, não é um filme de Ação como você gosta, mas aborda Artes Marciais que você gosta”.

Nudes e Jannach (2017) apresentam observações adicionais sobre conteúdo de explicações: elas podem ser adaptadas ao contexto (por exemplo, de acordo com o nível de conhecimento do usuário), pode haver fontes externas de informação para a explicação (por exemplo, tirar proveito de explicação *reviews* de produtos em *e-commerce*); pode haver explicações interativas (por exemplo, a explicação poderia tem uma pergunta “e se...” indicando o que recomendaria se um *input* fosse conhecido – “e se... você gostasse de filmes Asiáticos, teria a seguinte lista de filmes recomendados: ...”).

Em relação à apresentação de explicações de recomendação, a abordagem mais comum é apresentar explicações em linguagem natural, ou seja, apresentar um texto com a explicação ao usuário. Geralmente a explicação é um *template* instanciado ao gerar a explicação. Outra abordagem é apresentar explicações de forma gráfica para o usuário, por exemplo, mostrando um histograma com as notas que usuários similares ao usuário deram a um filme (HERLOCKER *et al.*, 2000).

Nudes e Jannach (2017) descrevem outras formas de apresentação, tais como, explicações em linguagem natural via áudio, rastros de inferência, explicações usando OWL (*Ontology Web Language*) traduzidas para uma linguagem interpretável pelo usuário final, etc.

Outro ponto relacionado à apresentação e conteúdo de explicações são os estilos de explicação. Tintarev e Masthoff (2015) apresentam uma lista de exemplos de explicações em sistemas comerciais e da academia (Quadro 2).

**Quadro 2: Alguns exemplos de explicações em sistemas comerciais e da academia**

Sistema	Exemplo de explicação	Estilo
Netflix	Filmes similares aos filmes que você que você gostou, ou seja, que deu notas 4 ou 5 no passado	baseado em casos
Amazon	“Clientes que compraram esse item também compraram ...”	baseado em colaboração
New Dudes (BILLSUS; PAZZANI, 1999)	“Esta notícia [recomendada] recebeu uma pontuação de relevância ‘Alta’ <i>porque</i> contém as palavras X, Y e Z [de seu interesse].”	baseado em conteúdo
(THOMPSON, <i>et al.</i> , 2004)	Diálogo, por exemplo, “Onde você gostaria de comer essa noite?” “Oh, talvez um lugar com comida Indiana”. “Que tal X, <i>porque</i> é o mais barato.”	conversacional
INTRINGUE (ARDISSON O <i>et al.</i> , 2003)	“Para as crianças [esse item] é muito atraente, requer pouco conhecimento sobre o assunto, [...], e a visita é bastante curta. [...]”	baseado em demografia
“Organizacion al Structure” (PU; CHEN, 2006)	“Também recomendamos os seguintes computadores <i>porque</i> eles são mais baratos e leves, embora tenham menor velocidade do processador.”	baseado em conhecimento/ utilidade

Tintarev e Masthoff (2015) indicam que o estilo de recomendação pode estar associado ou não ao algoritmo de recomendação. Por exemplo, em sistemas de recomendação baseados em conhecimento, explicação no estilo Baseado em Conhecimento/Utilidade são mais fáceis de serem geradas. Por outro lado, os objetivos de explicação podem guiar o estilo de explicação a ser adotado pelo sistema. Por exemplo, um dado sistema de recomendação baseado em conhecimento utiliza um estilo Conversacional para atingir o objetivo Confiança.

### 2.3.4 Geração de Explicações

Conforme apresentado na Seção 2.1, existem diferentes categorias de sistemas de recomendação (baseados em filtragem colaborativa, baseados em conteúdo, baseados em conhecimento, sensíveis ao contexto e híbridos). Cada uma dessas categorias é implementada por diferentes abordagens, por exemplo, sistema de recomendação baseados em filtragem colaborativa podem ser implementados utilizando-se abordagens baseados em vizinhança, baseadas em modelos de fatores latentes, baseadas em modelos probabilísticos, baseados em grafos, etc.

A grande maioria dos trabalhos sobre explicação não mostra como gerar a explicação porque essa está diretamente relacionada com o modelo de inferência e com os dados utilizados pelo sistema. Se é uma abordagem baseada em conhecimento, a explicação geralmente apresenta as regras de inferência utilizadas na recomendação. Se é uma abordagem sensível ao contexto, a explicação geralmente mostra os dados de contexto incorporados no processo de recomendação. Se é uma abordagem baseada em conteúdo, geralmente mostra as preferências do usuário utilizadas no processo de filtragem. Se é uma abordagem baseada em filtragem colaborativa baseada em vizinhança, geralmente se explica informando dados de outros usuários ou usando-se explicações gráficas.

Em sistema de recomendação baseados em filtragem colaborativa implementados através de modelos de fatores latentes, tais como, fatoração de matrizes, é difícil gerar explicações que sejam intuitivas ao usuário final. Um trabalho que busca resolver isso é Zhang *et al.* (2014), que propõem uma abordagem baseada em modelo de fatores latentes, que simultaneamente pode gerar recomendações com alta acurácia e explicações dessas recomendações. Para isso, esse trabalho propõe utilizar não apenas as avaliações numéricas dos usuários sobre os itens, mas também análise de sentimento em *reviews* dos itens dados pelos usuários. Na lista de itens recomendados, os itens recebem explicações no seguinte *template* “*You might be interested in [product feature], on which this product performs well.*”. Ou seja, uma fonte de informação auxiliar é usada para explicar a recomendação baseada em modelo de fatores latentes.

Um grande desafio da atualidade é gerar explicações que sejam interpretáveis e persuasivas de modelos complexos de recomendação baseados em algoritmos de aprendizagem de máquina (JUGOVAC; JANNACH, 2017). Nesse sentido estão começando a aparecer métodos de geração de explicação que são desacoplados do algoritmo de geração de recomendação, por exemplo, Vig *et al.* (2009), que apresentam uma explanação baseada em *tags*. Por um lado, alivia-se o problema de gerar explicações de recomendação baseados em algoritmos de aprendizagem de máquina, por outro lado, isso compromete a transparência do sistema.

Um fator que direciona a geração de explicações é o objetivo, conforme mostra o Quadro 1. Nunes e Jannach (2017) indicam que a maioria das explicações, em

diferentes tipos de sistemas inteligentes, são geradas com foco em Transparência, Eficiência, Confiança e Persuasão.

### 2.3.5 Avaliação de Explicações de Recomendação

A abordagem predominante de avaliação de explicação de recomendação é a avaliação centrada no usuário. Geralmente são realizados experimentos do tipo estudo de usuário com dezenas ou centenas de participantes, em protótipos; ou experimentos online, com centenas ou milhares de usuários, em sistemas reais de instituições ou de empresas.

Por exemplo, a Figura 2 mostra parte dos resultados da avaliação de uma abordagem de explicação de recomendação que busca incorporar dados de contexto na explicação (SATO *et al.*, 2018). Nessa avaliação foram apresentadas recomendações de restaurantes para 85 usuários. Esse é um exemplo de explicação: “*This restaurant is recommended to you because the restaurant is suitable for dates with your girlfriend/boyfriend*”. Na figura são mostrados os resultados da pesquisa de duas perguntas: “a explicação foi útil para escolha?” e “a explicação foi fácil de entender?”. Para cada uma delas havia diferentes estilos de apresentação de explicação de recomendação, tais como, informando somente dados demográficos do usuário, informando somente dados de contexto, dados demográficos e de contexto, etc.

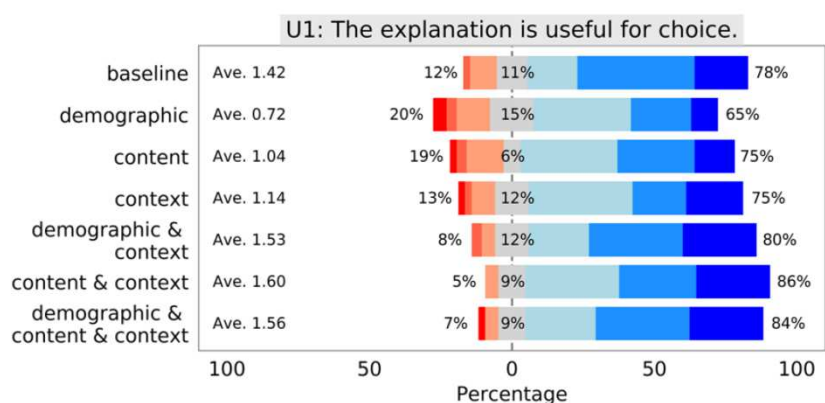


Figura 2: Exemplo de Apresentação de Resultados de Avaliação de Explicação de Recomendação, de Sato et al. (2018)

### 3. A Pesquisa Bibliográfica Realizada

Realizamos uma revisão bibliográfica com o objetivo de descobrir como é a geração de explicação de recomendação com diversificação. Inicialmente foram analisados diferentes *surveys* de explicação de recomendação, de diversificação de recomendação e de sistemas de recomendação (TINTAREV; MASTHOFF, 2015; NUNES; JANNACH, 2017; JUGOVAC; JANNACH, 2017; KUNAVAR, M.; POZRL; 2017; CASTELLS et al., 2015). Com isso desenvolvemos a seguinte string de busca, em formato de expressão lógica:

(explanation OR explaining OR justification OR argumentation)  
 AND (recommendation OR recommender)  
 AND (novelty OR diversity OR serendipity OR diversification)

Depois, essa *string* foi executada em cada um dos quatro principais repositórios de artigos científicos usados na Ciência da Computação: ACM Digital Library, IEEE Explorer, Springer Link e ScienceDirect. Para a execução foi necessário adaptar a *string* à sintaxe de consulta de cada repositório.

Com base nos resultados constatou-se que a palavra “explanation” e suas flexões e sinônimos são extremamente genéricas, o que geraram muitos resultados não relevantes. Em especial, no repositório ScienceDirect vieram no resultado da busca dezenas de estudos da área de Administração e Medicina/Biologia pela união das palavras “explanation”+ “recommendation”+ “novelty”. Durante a filtragem de artigos foram encontrados trabalhos estendidos, ou seja, publicados em uma conferência, e depois, expandidos para um *journal*, tais como, Pu e Chen (2006) e Pu e Chan (2007).

Foram encontrados apenas seis artigos relevantes, descritos na próxima subseção. Constatou-se que *nenhuma* pesquisa propôs ainda estudar como gerar explicação de recomendação com diversificação. Foram encontrados apenas trabalhos que indicam a necessidade de haver explicação de recomendação com diversificação. Esses trabalhos e outros, que dão ideia de forma indireta como gerar explicação de recomendações com diversidade, são apresentados a seguir.

### 3.1 Trabalhos Relevantes

Castagnos, et al. (2013) analisa o impacto da diversidade dentro de listas de recomendação na satisfação do usuário. Nesta pesquisa foi realizado um estudo de usuário exploratório, contendo 250 participantes, e comparou 5 abordagens de recomendação: baseadas em filtragem colaborativa, filtragem baseada em conteúdo e popularidade, que incluem ou não diversidade em recomendação. Os resultados mostram que os usuários perceberam quando há diversidade na recomendação e que, quando as recomendações são apresentadas, a diversidade pode reduzir a taxa de aceitação do sistema pelos usuários; por outro lado isso ajuda a aumentar a satisfação dos usuários. O usuário tem mais certeza de qual item escolher quando os itens da lista de itens recomendados apresentam diferença entre si.

Além disso, este estudo mostra que, apesar de ter um impacto positivo na satisfação dos usuários, a diversidade deve ser usada com cuidado, já um alto grau de diversidade pode resultar em usuários que não entendem a coerência de recomendações fornecidas.

Os autores salientam que a diversidade na lista de itens recomendados pode exigir explicação de recomendação, porque o usuário pode não entender a relação entre suas preferências e os itens recomendados pelo sistema.

Tintarev e Masthoff (2015) é um *survey* em explicação de recomendação. Nesse trabalho os autores citam o problema do “filtro de bolha”, que é um problema inerente de sistemas de filtragem de informação da atualidade, tais como, sistemas de recomendação e motores de busca na Web, onde o usuário tem acesso apenas uma porção da quantidade de itens de informação existentes em um sistema. De acordo com Pariser (2012), o “filtro de bolha” diz respeito ao isolamento do usuário em relação a uma diversidade de conteúdos e experiências, tornando-o menos propenso a descobrir e aprender coisas novas.

Paralelo a isso os autores indicam que existe um conjunto de trabalhos que busca modelar a serendipidade em sistemas de recomendação (ou seja, recomendar itens com novidade para o usuário e inesperados ou não óbvios) e há um conjunto de trabalhos que

indicam que aumentando a diversidade em recomendação ajuda-se o usuário a encontrar itens. Nesse contexto, os autores indicam que explicações de recomendação podem ajudar o usuário a aceitar itens que são novidade para ele e são inesperados ou não óbvios.

Pu e Chen (2006) e Pu e Chen (2007) é uma série de trabalhos que mostra uma forma estruturada de apresentação de itens recomendados pelo sistema de recomendação baseado em conhecimento. Os itens recomendados são apresentados como uma tabela, com diferentes colunas que correspondem aos atributos dos itens. Por exemplo, uma lista de computadores recomendados tem, para cada item, as colunas “preço”, “velocidade do processador”, “duração da bateria”, “capacidade de HD”, “peso”, etc. Além disso, os itens da lista de itens recomendando são agrupados por categorias, onde cada categoria é identificada por um *label* (que é uma explicação de recomendação) e agrupa itens similares.

Por exemplo, a lista de itens recomendados é dividida em subgrupos: o primeiro subgrupo é identificado pela explicação “o computador mais popular”, o segundo subgrupo é identificado pela explicação “computadores mais baratos e mais leves, porém com velocidade de processador menor”, o terceiro grupo é identificado pela explicação “computadores com maior velocidade de processador e maior capacidade de HD, porém mais pesados”, etc. Essa organização estruturada de itens recomendados acompanhada de explicações ajudam o usuário a melhor escolher o item.

Esse conjunto de explicações dentro de uma lista de itens recomendados poderia servir de base para o desenvolvimento de um novo estilo de explicação para de itens em recomendações com diversificação. Por exemplo, “o item X tem apenas 30% de similaridade com os itens que você costuma usar, porém apresenta a seguinte vantagem ...”. É uma forma de persuadir o usuário a usar itens da recomendação com diversificação, mostrar uma utilidade da recomendação para o usuário.

Em Chen e Pu (2007), essa interface de apresentação de itens recomendados de forma estruturada foi utilizada para mostrar recomendações com diversidade. Nesta interface, itens com atributos semelhantes são agrupados em categorias, e a diversidade entre itens em diferentes categorias é maximizada. Posteriormente, em Hu e Pu (2011), foi conduzido um estudo de usuário na área de *e-commerce* para medir a percepção de usuário nessa interface orientada à diversidade em relação à lista típica de itens (um item após o outro sem agrupamentos). Os resultados mostraram que nessa nova interface o usuário percebe mais facilmente a recomendação com diversidade, e que consegue localizar mais facilmente os itens que quer comprar.

Esses dois últimos trabalhos mostram estudos que relacionam explicação de recomendação, projeto de interface de usuário e diversidade em recomendação. Por exemplo, uma mesma explicação apresentada de formas diferentes na interface tem impactos diferentes na diversidade. Portanto, a qualidade da recomendação gerada e da interface do sistema pode *influenciar* a avaliação de uma explicação de recomendação pelo usuário. A interface é fácil de ser mantida estática em experimentos, porém a qualidade da recomendação depende de outros fatores *não controláveis*, como expansividade de dados no *dataset* onde o algoritmo de recomendação foi treinado.

Zanker e Ninaus (2010) apresenta uma abordagem de recomendação baseado em conhecimento que objetiva desacoplar a lógica de recomendação da lógica de explicação de recomendação. O objetivo específico dessa abordagem é construir automaticamente argumentos convincentes específicos para usuário sobre porque um determinado item combina com os interesses do perfil de usuário. Tecnicamente, isso é



realizado com um modelo de explicação baseado em conhecimento e um método de raciocínio independente do mecanismo de recomendação aplicado.

Esse trabalho mostra a ideia de apresentar explicações convincentes ao usuário, o que pode ser utilizado para persuadi-lo a utilizar/comprar itens recomendados com diversificação, utilizando um *módulo externo* ao sistema de recomendação. Esse módulo externo pode ser utilizado naqueles sistemas de recomendação que funcionam como “caixas pretas”, não sendo transparentes sobre como chegam aos resultados que produzem e/ou utilizam algoritmos de aprendizagem de máquina não intuitivos. Por outro lado, conforme citado previamente, isso pode comprometer a transparência do sistema.

#### **4. Considerações Finais e Trabalho Futuro**

Essa pesquisa teve o objetivo de investigar abordagens de explicação de recomendações com diversificação, ou seja, para as recomendações geradas por sistemas de recomendação que estabelecem um equilíbrio adequado entre acurácia e diversidade, ou entre acurácia, diversidade e novidade.

A partir da pesquisa bibliográfica apresentada constatou-se que nenhuma pesquisa propôs ainda estudar como gerar explicação de recomendação com diversificação. Foram encontrados apenas trabalhos que indicam a necessidade de haver explicação de recomendação com diversificação: Castagnos *et al.*, 2013; Tintarev; Masthoff, 2015.

Além disso, acredita-se que com tais explicações seja possível (I) minimizar o problema da “bolha de filtro”, que diz respeito ao isolamento do usuário em relação a uma diversidade de conteúdos e experiências, tornando-o menos propenso a descobrir e aprender coisas novas (PARISER, 2012); e (II) aumentar a satisfação do usuário.

A partir dessa constatação de necessidade de pesquisa propõem-se, como trabalho futuro, investigar e desenvolver uma abordagem de explicação de recomendação com diversificação que apresenta esses dois objetivos simultaneamente: (I) Transparência: para ajudar o usuário a *entender* a relação entre suas preferências e os itens recomendados pelo sistema, dos quais alguns podem ser diferentes dos itens que o usuário usou/avaliou no passado; (II) Persuasão: para ajudar o usuário a *aceitar* itens que são novidade para ele e são inesperados ou não óbvios (serendipidade). Essa abordagem terá que gerar explicações que sejam interpretáveis e persuasivas de modelos complexos de recomendação baseados em algoritmos de aprendizagem de máquina.

Em relação à avaliação experimental dessa abordagem de explicação de recomendação a ser desenvolvida, pretende-se aplicar e avaliar ela sob o domínio de cidades inteligentes. Será possível aplicar/avaliar tal abordagem de explicação de recomendação sobre duas abordagens de recomendação com diversificação atualmente em desenvolvimento dentro do projeto universal do CNPq, recém-iniciado dentro do grupo de pesquisa de Sistemas de Informação do INF-UFRGS. Esse projeto visa recomendar recursos informacionais espalhados em uma cidade inteligente para o cidadão, tais como, locais para caminhada, locais para participar de trabalho voluntário, exposições culturais, etc., de forma que ele conheça e aproveite mais de sua cidade, melhore sua qualidade de vida e contribua para uma sociedade melhor.

## Referências

- Adomavicius, G. and Kwon, Y. Toward More Diverse Recommendations: Item Re-Ranking Methods for Recommender Systems. Phoenix, Arizona,: [s.n.], 2009.
- Adomavicius, G. and Tuzhilin, A. Context-aware recommender systems. In: Recommender systems handbook. Springer, Boston, MA, 2011. p. 217-253.
- Ardissono, L. et al. Intrigue: personalized recommendation of tourist attractions for desktop and hand held devices. *Applied artificial intelligence*, v. 17, n. 8-9, p. 687-714, 2003.
- Banavar, G. Learning to trust artificial intelligence systems. Accountability, Compliance and Ethics in the Age of Smart Machines, IBM Global Services, 2016
- Billsus, D. and Pazzani, M. J. A personal news agent that talks, learns and explains. In: Proceedings of the third annual conference on Autonomous Agents. ACM, 1999. p. 268-275.
- Castagnos, S., Brun, A. and Boyer, A. When Diversity Is Needed... But Not Expected!. In: International Conference on Advances in Information Mining and Management. IARIA XPS Press, 2013. p. 44-50.
- Castells, P., Hurley, N. J. and Vargas, S. Novelty and diversity in recommender systems. In: Recommender Systems Handbook. Springer, Boston, MA, 2015. p. 881-918.
- Chen, L. and Pu, P. Preference-based organization interfaces: aiding user critiques in recommender systems. In: *User Modeling 2007*, pp. 77–86. Springer, Heidelberg (2007)
- Galway, N. U. I. XPLODIV: DIVERSIFICATION APPROACH FOR RECOMMENDER SYSTEMS. [S.l.]: [s.n.], 2015. Disponível em: <<https://aran.library.nuigalway.ie/handle/10379/5081>>.
- Goldberg, D. et al. Using Collaborative Filtering to Weave an Information Tapestry. New York, NY, USA: Commun. ACM, 1992. v. 35, n. 12, p. 61–70. Disponível em: <<http://doi.acm.org/10.1145/138859.138867>>.
- Herlocker, J. L., Konstan, J. A. and Riedl, J. Explaining collaborative filtering recommendations. In: Proceedings of the 2000 ACM conference on Computer supported cooperative work. ACM, 2000. p. 241-250.
- Herlocker, J. L. et al. Evaluating collaborative filtering recommender systems. *ACM Transactions on Information Systems*, 1 jan. 2004. v. 22, n. 1, p. 5–53.
- Holman, W. and Jenkins, J. Google and the Search for the Future. The Wall Street Journal, [S.l.], 2010. Disponível em: <<https://www.wsj.com/articles/SB10001424052748704901104575423294099527212>>. Acesso em: 12 maio 2018.
- Hu, R. and Pu, P. Helping Users Perceive Recommendation Diversity. In: DiveRS@ RecSys. 2011. p. 43-50.
- Jannach, D. and Adomavicius, G. Recommendations with a Purpose. New York, New York, USA: ACM Press, 2016. p. 7–10. Disponível em: <<http://dl.acm.org/citation.cfm?doid=2959100.2959186>>.

- Jugovac, M. and Jannach, D. Interacting with recommenders—overview and research directions. *ACM Transactions on Interactive Intelligent Systems (TiiS)*, v. 7, n. 3, p. 10, 2017.
- Kunaver, M. and Pozrl, T. Diversity in recommender systems—A survey. *Knowledge-Based Systems*, v. 123, p. 154-162, 2017.
- Knijnenburg, B.P., Willemsen, M.C., Gantner, Z. and Soncu, H. and Newell, C.: Explaining the user experience of recommender systems. *User Model. User-Adapt. Interact.* 22(4–5), 441–504 (2012). doi:10.1007/s11257-011-9118-4
- Lemire, D., Downes, S. and Paquet, S. Diversity in open social networks. Published Online, 2008. Disponível em: <[http://lemire.me/fr/documents/publications/DiversityTechReport\\_October2008.pdf](http://lemire.me/fr/documents/publications/DiversityTechReport_October2008.pdf)>.
- McNee, S. M., Riedl, J. and Konstan, J. A. Being accurate is not enough. New York, New York, USA: ACM Press, 2006. p. 1097. Disponível em: <<http://dl.acm.org/citation.cfm?doid=1125451.1125659>>.
- Murakami, T., Mori, K. and Orihara, R.: Metrics for evaluating the serendipity of recommendation lists. In: K. Satoh, A. Inokuchi, K. Nagao, T. Kawamura (eds.) *New Frontiers in Artificial Intelligence, Lecture Notes in Computer Science*, vol. 4914, pp. 40–46. Springer Berlin Heidelberg (2008)
- Nunes, I. and Jannach, D. A systematic review and taxonomy of explanations in decision support and recommender systems. *User Modeling and User-Adapted Interaction*, v. 27, n. 3-5, p. 393-444, 2017.
- Pariser, E. *The Filter Bubble: How the New Personalized Web is Changing what We Read and how We Think*. [S.l.]: Penguin Books, 2012.
- Pu, P. and Chen, L. Trust building with explanation interfaces. In: *Proceedings of the 11th international conference on Intelligent user interfaces*. ACM, 2006. p. 93-100.
- Pu, P. and Chen, L. Trust-inspiring explanation interfaces for recommender systems. *Knowledge-Based Systems*, v. 20, n. 6, p. 542-556, 2007.
- Resnick, P. et al. GroupLens: An Open Architecture for Collaborative Filtering of Netnews. *Proceedings of the 1994 ACM conference on Computer supported cooperative work*, 1994. p. 175–186.
- Ribeiro, M.T., Ziviani, N., Moura, E.S.D., Hata, I., Lacerda, A. and Veloso, A.: Multiobjective pareto-efficient approaches for recommender systems. *ACM Trans. Intell. Syst. Technol.* 5(4), 53:1–53:20 (2014).doi:10.1145/2629350
- Ricci, F. et al. *Recommender Systems Handbook*. 1st. ed. Boston, MA: Springer US, 2011.
- Ricci, F. et al. *Recommender Systems Handbook*. 2st. ed. Boston, MA: Springer US, 2015.
- Said, A. et al. Increasing Diversity Through Furthest Neighbor-Based Recommendation. In *Proceedings of the fifth ACM International Conference on Web Search and Data Mining*, 2012. p. 1–4. <http://www.dcs.gla.ac.uk/workshops/ddr2012/papers/p3said.pdf>.
- Sato, M. et al. Explaining Recommendations Using Contexts. In: *23rd International Conference on Intelligent User Interfaces*. ACM, 2018. p. 659-664.

- Tintarev, N. and Masthoff, J. Explaining recommendations: Design and evaluation. In: Recommender systems handbook. Springer, Boston, MA, 2015. p. 353-382.
- Thompson, C. A.; Goker, M. H. and Langley, P. A personalized system for conversational recommendations. *Journal of Artificial Intelligence Research*, v. 21, p. 393-428, 2004.
- Willemsen, M. C., Graus, M. P. and Knijnenburg, B. P. Understanding the role of latent feature diversification on choice difficulty and satisfaction. *User Modeling and User-Adapted Interaction*, v. 26, n. 4, p. 347-389, 2016.
- Vig, J., Sen, S. and Riedl, J. Tagsplanations: explaining recommendations using tags. In: Proceedings of the 14th international conference on Intelligent user interfaces. ACM, 2009. p. 47-56.
- Zanker, M. and Ninaus, D. Knowledgeable explanations for recommender systems. In: Web Intelligence and Intelligent Agent Technology (WI-IAT), 2010 IEEE/WIC/ACM International Conference on. IEEE, 2010. p. 657-660.
- Ziegler, C. N. et al. Improving recommendation lists through topic diversification. New York, New York, USA: ACM Press, 2005. p. 22. Disponible em: <<http://portal.acm.org/citation.cfm?id=1060754%5Cnhttp://portal.acm.org/citation.cfm?doid=1060745.1060754>>.
- Zhang, Y. et al. Explicit factor models for explainable recommendation based on phrase-level sentiment analysis. In: Proceedings of the 37th international ACM SIGIR conference on Research & development in information retrieval. ACM, 2014. p. 83-92.
- Zhang, F. Improving recommendation lists through neighbor diversification. New York, New York, USA: IEEE, 2009. p. 222-225. Disponible em: <<http://portal.acm.org/citation.cfm?doid=1060745.1060754>>.
- Zhang, M. and Hurley, N. Novel Item Recommendation by User Profile Partitioning. [S.l.]: IEEE, 2009. V. 1, p. 508-515. Disponible em: <<http://ieeexplore.ieee.org/document/5286022/>>.
- Zhang, Y.C., Séaghdha, D.O., Quercia, D. and Jambor, T.: Auralist: Introducing serendipity into music recommendation. In: Proceedings of the 5th ACM Conference on Web Search and Data Mining, WSDM 2012, pp. 13-22. ACM, New York, NY, USA (2012)