

Diversificação de Recomendação em Cidades Inteligentes: Estudo e Estrutura de Abordagem

Gabriel Machado Lunardi, Guilherme Medeiros Machado e
José Palazzo Moreira de Oliveira

Instituto de Informática – Universidade Federal do Rio Grande do Sul (UFRGS)
Caixa Postal 15.064 – 91.501-970 – Porto Alegre – RS – Brazil

{gmlunardi, guimmachado, palazzo}@inf.ufrgs.br

Abstract. *The use of Recommendation Systems in virtually all online services nowadays makes people interact with them more and more, especially when considering the domain of intelligent cities. However, these systems have accumulated criticism over time because of their overemphasis on similarity, which ultimately produces recommendations that are often obvious and redundant and puts users in a "filter bubble", limiting their experiences. As a solution, the diversification of recommendation arises, which implies a problem of how to balance the accuracy and diversity since the increase of diversity decreases the accuracy and vice versa. Existing works diversify using post-filtering or modifications in the recommendation algorithm, being the first approach the most common. Therefore, this article proposes an outline hybrid approach that seeks to maximize diversity with minimum losses of accuracy applied in the domain of intelligent cities, in order to mitigate the "filter bubble" effect.*

Resumo. *O emprego de Sistemas de Recomendação em praticamente todos os serviços on-line, na atualidade, faz com que as pessoas interajam com eles cada vez mais, principalmente quando se considera o domínio de cidades inteligentes. Entretanto, esses sistemas têm acumulado críticas ao longo do tempo devido à sua ênfase demasiada em similaridade, que acaba produzindo recomendações que são muitas vezes óbvias e redundantes e coloca os usuários em uma "bolha de filtro", limitando suas experiências. Como solução, surge a diversificação de recomendação, que implica em um problema de como balancear a acurácia e diversidade já que o aumento da diversidade diminui a acurácia e vice-versa. Trabalhos existentes buscam diversificar utilizando pós-filtragem ou com base no próprio algoritmo de recomendação sendo, a primeira abordagem, a mais comum. Portanto, neste artigo é proposto, a partir de um vasto estudo bibliográfico, um esboço de abordagem híbrida que busca maximizar a diversidade com perdas mínimas de acurácia, aplicada no domínio de cidades inteligentes, visando atenuar o efeito de "bolha de filtro".*

1. Introdução

Os Sistemas de Recomendação (SR) foram inventados na década de 1990 com o intuito de auxiliar usuários a encontrarem itens relevantes em meio a arranjos desses [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 and Jenkins 2010]. Sendo assim, considerando que a maioria das pessoas, atualmente, experiência a *Web* através dos serviços citados, os SR tornaram-se onnipresentes, trazendo benefícios como a diminuição da sobrecarga de informação sobre o usuário, o aumento da receita de fornecedores, a fidelização de clientes, o apoio a tomada de decisão, dentre outros [Jannach and Adomavicius 2016].

Os modelos mais conhecidos de recomendação baseiam-se em encontrar itens semelhantes aos preferidos pelos usuários no passado (baseados em conteúdo) ou aqueles consumidos por usuários semelhantes (filtragem colaborativa) ou um híbrido dessas técnicas [Ricci et al. 2011]. No entanto, esses métodos têm acumulado críticas ao longo do tempo devido à sua ênfase demasiada em similaridade, produzindo recomendações que são muitas vezes óbvias e redundantes. Por exemplo, recomendar outras músicas do mesmo artista que o usuário gostou no passado pode ser muito preciso, mas muitas vezes menos útil do que identificar artistas desconhecidos para o usuário experimentar [Kapoor et al. 2015].

Dessa forma, a ênfase em similaridade produz o indesejável efeito de “bolha de filtro” que, de acordo com Pariser (2012), 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. Esse efeito pode ser atenuado através da diversificação da recomendação que visa a sugestão de novidades para o usuário. Entretanto, Ricci *et al.* (2011) salientam que o aumento da diversidade diminui a acurácia da predição de *rating* (que corresponde à probabilidade de o usuário gostar do item recomendado) e vice-versa.

Portanto, a possível solução para o efeito da “bolha de filtro”, ou seja, a diversificação, implica em um problema computacional que pode ser visto sob a ótica de como balancear a recomendação entre qualidade (em termos de acurácia) e diversidade (do ponto de vista da exploração do perfil de usuário e de novos itens). Kapoor *et al.* (2015) defendem que a falta de um equilíbrio entre essas duas dimensões compromete a experiência do usuário, sobretudo se a diversificação for realizada de forma inadvertida, ou seja, sem critérios.

Apesar de existentes, as abordagens para os problemas supracitados ainda não são maioria, se preocupando mais com problemas como a predição de *rating* [Knijnenburg et al. 2016]. Recentemente, Jannach e Adomavicius (2016) fizeram uma análise das publicações dos últimos dois anos na mais específica e notória conferência da área, a ACM RecSys, na qual constataram que 80% dos artigos se preocupam com predição de *rating* e somente 20% deles abordam questões como diversificação e novidade. Com isso, existem poucos trabalhos tentando desenvolver características que não são relacionadas à acurácia e, por conta disso, existe uma preocupação crescente da comunidade científica em desenvolver sistemas que olhem para características “além da acurácia”. Uma dessas características é a diversificação a qual vem sendo estimulada cada vez mais em *workshops* e em conferências mundiais, como a ESWC *Linked Open*

Data-enabled Recommender Systems Challenge em 2014 [Codem et al. 2014] e a trilha específica criada na RecSys: *Beyond the Accuracy* [Ge et al. 2010]. Sendo assim, isso mostra que existe um crescente interesse da comunidade científica na área, e por ser um tema recente, mostra potencial de pesquisa.

Além disso, um domínio possível e emergente para a aplicação e validação dessas abordagens, além dos já citados no primeiro parágrafo, é o de cidades inteligentes. Uma cidade inteligente pode ser definida por Nam e Pardo (2011) como “o uso de tecnologias de Computação Inteligente para tornar os componentes de infraestrutura crítica e serviços de uma cidade - que incluem administração, educação, saúde, segurança pública, imobiliário, transporte e serviços públicos - mais inteligentes, interconectados e eficientes”.

Nesse sentido, a recomendação de recursos em ambientes inteligentes, tal como uma cidade dessa natureza, exige que a abordagem passe a considerar informações de contexto, além das informações do usuário e do item a ser recomendado. Isso se torna necessário, pois os recursos a serem recomendados muitas vezes estão espalhados pelo ambiente e o conhecimento de informações contextuais como localização e tempo são necessárias para que a recomendação seja efetiva. Um exemplo desse tipo é a recomendação de locais turísticos. Nesse cenário a informação de localização do usuário e dos locais além da informação do horário de funcionamento dos locais, bem como o tempo disponível do usuário são algumas informações contextuais que devem ser levadas em consideração para que a recomendação seja efetiva. Sistemas de recomendação cientes de contexto apresentam as características desejadas para este tipo de tarefa [Adomavicius et al. 2005].

Com base no exposto, esta proposta objetiva desenvolver uma abordagem de recomendação diversificada, aplicada no domínio de cidades inteligentes, levando em consideração o balanceamento entre qualidade e diversidade. Com isso, acredita-se que seja possível resolver o problema da “bolha de filtro” e aumentar a satisfação e experiência do usuário.

Este artigo está organizado da seguinte forma: a seção 2 apresenta a fundamentação conceitual, dando destaque para ubiquidade, consciência de contexto, sistemas de recomendação e diversificação; a seção 3 traz os trabalhos relacionados; a seção 4 apresenta e discute a abordagem e possibilidades de experimentos; a seção 5, por fim, apresenta a conclusão e trabalhos futuros.

2. Fundamentação Conceitual

A fundamentação conceitual introduz conceitos básicos sobre ubiquidade, consciência de contexto, sistemas de recomendação e diversificação.

2.1. Ubiquidade

A computação ubíqua foi primeiramente proposta por Weiser (1993), que visionou uma mudança de paradigmas na maneira como as pessoas interagiriam com a computação. Nesse novo paradigma os serviços oferecidos pela computação estariam tão integrados à vida do usuário e este estaria tão habituado a interagir com tais tecnologias que a computação desapareceria no plano de fundo.

Tal mudança de paradigma também foi tratada, anos mais tarde, sob a ótica da Web. Berners-Lee em seu clássico trabalho sobre a web semântica previu que os usuários e a web estariam integrados de maneira transparente e que a integração entre os dois ocorreria de maneira natural [Berners-Lee et al. 2001]. Na visão de Berners-Lee, não só o usuário entenderia a Web, mas a Web também entenderia o usuário e poderia oferecer-lhe serviços.

2.2. Consciência de Contexto

A informação de contexto é um dos elementos de fundamental importância utilizados na computação ubíqua, pois é através dela que se tenta entender o relacionamento entre a computação e o contexto no qual ela está inserida. Um exemplo direto que mostra a importância dessa informação é que ao mover um computador para fora da mesa de trabalho talvez seja necessário acompanhar para onde ele se foi [Dourish 2004].

Dey (2001) propõe uma das definições de contexto mais notórias da literatura, e adotadas neste trabalho. Nela é definido que:

Contexto é qualquer informação que pode ser utilizada para caracterizar a situação de uma entidade. Uma entidade é uma pessoa, lugar ou objeto que é considerada relevante para a interação entre o usuário e a aplicação, incluindo o próprio usuário e a aplicação.

O trabalho de Dourish (2004) classifica o contexto segundo sua origem, na computação ubíqua, em duas vertentes. Na primeira, o contexto é encarado como um problema representacional, da mesma forma que sistemas de software são representacionais, e por causa disso, uma preocupação principal é como o contexto pode ser codificado e representado. Quatro suposições baseiam essa vertente:

- Contexto é uma forma de informação, ou seja, é algo que pode ser conhecido e por isso codificado e representado.
- Contexto é delineável. Para um dado conjunto de aplicações ou requisitos, pode-se definir antecipadamente o que irá contar como contexto de atividades que a aplicação suporta e executa.
- Contexto é estável. Apesar dos elementos de representação de contexto variarem de aplicação para aplicação, eles não variam de instância para instância de uma atividade ou de um evento. A determinação da relevância de qualquer potencial elemento de contexto pode ser realizada uma única vez.
- Contexto e atividade são separáveis. As atividades ocorrem dentro de um contexto. Esse, por sua vez, descreve características do ambiente no qual a atividade ocorre, mas são separadas da atividade. Uma pessoa pode estar conversando com outra em um local, então a conversa é a atividade da pessoa e o local o aspecto de contexto.

Essas quatro suposições baseiam a noção de contexto na área de pesquisa em computação ubíqua, independentemente da definição de contexto adotada. A ideia que o contexto consiste de um conjunto de características de um ambiente que circunda uma atividade genérica, e que essas características podem ser codificadas e tornarem-se

disponíveis a um sistema de software junto com uma codificação da própria atividade, é uma suposição comum em vários sistemas.

Na segunda vertente o contexto é visto como um problema interacional que, segundo essa visão, o tipo de coisa a ser modelada pelas quatro suposições da vertente anterior não é o tipo de coisa que o contexto é. A principal diferença aqui é que o contexto não é visto como algo estático que pode ser observado e previsto, pelo contrário, ele depende da interação do usuário com o ambiente. Então, nessa visão, contexto não é algo que descreve um cenário e sim algo que as pessoas fazem. É uma realização, ao invés de uma observação, um resultado, ao invés de uma premissa. As quatro suposições que baseiam essa vertente são:

- Contextualidade é uma propriedade relacional que acontece entre objetos ou atividades, ao invés de ser visto como uma informação. Algo não é mais considerado ou não como contexto, ao invés disso esse algo pode ser, ou não, contextualmente relevante para uma determinada atividade.
- O escopo das características contextuais é definido dinamicamente, ao invés de considerar que o contexto pode ser delineado e definido antecipadamente.
- Contexto é uma propriedade ocasionada, ao invés de considerar o contexto como algo estativo, relevante para um cenário particular, instâncias particulares de uma ação e participantes particulares desta ação.
- Contexto surge da atividade, ao invés de considerar contexto e atividade como duas entidades separadas. O contexto não está simplesmente “vagando por aí”, mas é ativamente produzido e mantido no curso da atividade em questão.

Neste trabalho foi adotada a classificação de contexto como um problema representacional. Uma das vantagens ao encarar o contexto como este tipo de problema é que os elementos que irão participar do mesmo (ex. localização, data, preferências) tem um escopo mais limitado e podem ser previamente definidos, facilitando a modelagem das informações de contexto.

2.3. 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. Esta 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.

São encontrados, na literatura, vários sistemas de recomendação que se propõem a auxiliar o cumprimento dessas tarefas. Ricci *et al.* (2011) 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 ativo 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 a 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.

Dentre todas as técnicas, a filtragem colaborativa tornou-se o método mais popular e mais implementado pelos sistemas de recomendação tradicionais [Ricci et al. 2011].

2.4. Diversidade e diversificação

Uma definição básica e geral para o conceito de **diversidade** é: um conjunto é diversificado se houver um alto nível de heterogeneidade (dissimilaridade) entre os itens da coleção. Nesse caso, a principal propriedade dessa conceituação é a dissimilaridade que, em outras palavras, quer dizer o quão diferente os itens são entre si [Galway 2015].

De forma geral, a maneira mais comum de medir diversidade, fundada na definição citada, é quantificá-la como um agregado da dissimilaridade comparada entre os itens no conjunto [Nehring and Puppe 2002] [Lemire et al. 2008] [Hurley and Zhang 2011]. Como alternativa, Nehring e Puppe (2002) desenvolveram intuições básicas para uma teoria da diversidade e definiram uma abordagem multi-atributo para medir a diversidade: “a diversidade de um conjunto é simplesmente considerada como a soma dos valores numéricos (pesos) dos atributos pertencentes por algum Objeto no conjunto”. Uma abordagem diferente é medir a diversidade como a raridade média dos elementos no conjunto [Patil and Taillie 1982]. Para Patil e Taillie (1982), um item é raro se dificilmente puder ser encontrado dentro do conjunto.

Nesse sentido, a maneira mais comum de medir a dissimilaridade entre dois itens é como o inverso de sua similaridade. Se a similaridade for medida com o grau para o qual dois objetos compartilham as mesmas características/atributos, então a dissimilaridade medirá o grau das características únicas desses dois objetos comparados entre si. Portanto, uma coleção diversificada conteria itens que possuiriam uma grande proporção de características únicas e, portanto, maior cobertura de características gerais [Lemire et al. 2008].

Uma métrica de dissimilaridade mede quão diferentes ou “distantes” dois objetos são/estão um do outro. A medida de dissimilaridade é fundamental para medir a diversidade: “se a dissimilaridade não pode ser definida para um par de objetos, então é difícil imaginar como a dissimilaridade coletiva pode ser definida para uma coleção de mais de dois objetos” [Patil and Taillie 1982]. A primeira intuição é ver a dissimilaridade como uma função de distância. De acordo com Chen, Ma e Zhang, K. (2009), uma métrica $distancia(i,j)$ que mede a distância entre os objetos i e j deve respeitar os seguintes princípios:

- Não negatividade $distancia(i, j) \geq 0$
- Identidade indiscernível $distancia(i, j) = 0$ se e somente se $i = j$
- Simetria $distancia(i, j) = distancia(j, i)$
- Desigualdade triangular $distancia(i, j) \leq distancia(i, k) + distancia(k, j)$

Outra maneira de ver a dissimilaridade ou uma função de distância é como o contrário da similaridade. A similaridade ajuda a quantificar a informação mútua compartilhada entre dois objetos [Chen et al. 2009]. Os autores definem as seguintes regras para uma métrica de similaridade $sim(x,y)$ que a medir entre dois objetos x e y :

- $sim(x, y) = sim(y, x)$
- $sim(x, x) \geq 0$
- $sim(x, x) \geq sim(x, y)$
- $sim(x, y) + sim(y, z) \leq sim(x, z) + sim(y, y)$
- $sim(x, x) = s(x, y) = s(x, y)$ se e somente se $x = y$

Chen, Ma e Zhang, K. (2009) também propõem duas funções utilizadas para transformar uma métrica de similaridade $sim(x,y)$ em uma métrica de distância. Essa transformação pode ser vista na equação abaixo:

$$Fp(sim(x,y)) = \frac{sim(x,x) + s(y,y)}{2} - s(x,y)$$

$$Fm(sim(x,y)) = \max\{sim(x,x), sim(y,y)\} - s(x,y)$$

Por exemplo, se for definida a similaridade máxima como 1 e, portanto, $sim(x,x) = 1$ e $sim(y,y) = 1$, é possível ver que para ambas as transformações, surge a equação abaixo:

$$distancia(i,j) = 1 - sim(i,j)$$

Onde $distancia(i,j)$ é a distância entre objetos \bar{i} e \bar{j} , e $sim(i,j)$ a semelhança entre os mesmos objetos. Esta última definição é muito intuitiva e utilizada em várias aplicações, como em [McSherry 2002].

Conceituada diversidade é possível, então, definir **diversificação**, de forma genérica, como o processo de criação de um conjunto diversificado de elementos. A tarefa envolvida nesse processo é: selecionar um subconjunto de k elementos de um conjunto mais amplo \mathbb{S} a fim de maximizar uma função objetiva que considere tanto a qualidade quanto a diversidade dos elementos k . O desafio é que geralmente existe uma incompatibilidade entre diversidade e qualidade se o conjunto mais amplo contiver elementos que são semelhantes entre si, ou seja, se existe redundância dentro do conjunto de elementos. Isso significa que se um elemento é de alta qualidade, então todos os elementos similares também têm alta qualidade. No entanto, todos os elementos semelhantes não podem ser adicionados porque isso reduziria diversidade. O desafio é, então, como escolher k elementos para maximizar a qualidade e a diversidade ao mesmo tempo [Galway 2015].

Dentro do espectro de desenvolvimento dos SR vários são os fatores que justificam e norteiam a consideração da diversidade e da diversificação. Um deles é a incerteza do perfil de usuário, ou seja, há incompletude e ambiguidade nele. Isso pode ser explicado pelo grande tamanho dos espaços de itens e a inviabilidade de obter informações de classificação explícita em todos os produtos dos usuários, a falta de confiabilidade de interpretar informações implícitas para entender os gostos dos usuários e a natureza dinâmica das preferências do usuário. Com isso, a diversidade é uma boa solução diante da incerteza e um SR deve oferecer aos usuários um conjunto diversificado de sugestões representativas de seus gostos, a fim de aumentar as chances de eles encontrarem itens úteis nas recomendações [Vargas and Castells 2011] [Zheng et al. 2012].

Outro fator é a relação de serendipidade e novidade com diversidade. 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 está relacionada a uma noção mais forte de novidade e é definida como um item novo e inesperado ou não óbvio. Uma recomendação óbvia refere-se a um produto que o usuário poderia encontrar por conta própria, sem o auxílio do recomendador, por exemplo, um produto

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, mas não surpreendente.

Em essência, a serendipidade é apenas uma visão mais forte da novidade. Isso leva a uma visão da novidade como uma medida gradual, onde diferentes níveis de novidade podem ser alcançados dependendo de quão longe ou diverso um item é da experiência passada do usuário. A única evidência direta de experiência passada é dada pelo perfil do usuário. Dessa forma, um item inovador, mas óbvio, pode ser visto como “diferente” do perfil do usuário, mas não como “diferente” como um item surpreendente. No entanto, considerar apenas o perfil do usuário para definir a novidade não é suficiente, pois a experiência passada do usuário poderia ser definida por outros fatores, como a popularidade do produto. Para incentivar a descoberta de novos produtos, geralmente é desejável sugerir itens que pertençam a nichos menos populares, dado que é mais provável que os produtos populares já sejam conhecidos do usuário ou o usuário possa descobrir o produto por conta própria [Herlocker et al. 2004].

O problema de diversificação em SR tradicionais está no fato que eles não oferecem recomendações diversificadas por natureza. Os motivos estão relacionados à heurística das técnicas de recomendação tradicionais e às métricas de avaliação atuais, que ignoram a diversidade e avaliam uma lista de recomendações como um agregado dos itens individuais e não como uma entidade completa. Os motivos são os seguintes [Galway 2015]:

- a) *As heurísticas baseadas nas técnicas de recomendação fundamentam-se em medidas de similaridade que limitam a diversidade de itens considerados para recomendação:* é improvável que um SR ofereça sugestões diversas de produtos ao empregar técnicas de recomendação tradicionais centradas em heurísticas baseadas em similaridade. Esse problema pode levar à percepção de que um usuário só vê itens que são semelhantes ao já viu antes, o que comumente é referido como o “problema de bolha de filtro”. Resumidamente isso se deve a (i) superespecialização, (ii) a tendência para itens populares, e (iii) a tendência para itens que são semelhantes aos itens altamente classificados do perfil do usuário;
- b) *As métricas de avaliação que avaliam a qualidade individual dos itens nos SR penalizam diversidade e novidade:* a maioria das publicações sobre o tema da Avaliação de SR se concentra em métricas de acurácia. Em geral, essas métricas medem a capacidade do sistema em prever a utilidade/classificação que um usuário atribui a um produto que ainda não foi avaliado [Herlocker et al. 2004]. No entanto, métricas adicionais, tais como novidade e diversidade, devem ser consideradas para medir a satisfação do usuário, uma vez que a alta acurácia sozinha nem sempre indica que os usuários obterão sugestões de produtos interessantes que são úteis para fins práticos (satisfação do usuário) [Chen et al. 2013] [Herlocker et al. 2004] [McNee et al. 2006] [Adomavicius et al. 2008] [Ziegler et al. 2005].
- c) *A avaliação da lista de recomendações é realizada como um agregado dos itens individuais, desconsiderando o valor real dos itens no contexto da lista:* as métricas da lista de recomendação não avaliam cada produto no contexto da lista e não podem determinar se a lista oferece itens de alta qualidade e

suficientemente diversos para cobrir o espectro dos interesses do usuário [McNee et al. 2006].

De forma geral, recomendações diversas/novas 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 et al. 2008]. A diversificação também é uma possível solução para o problema de superespecialização [Kunaver and Poržl 2017].

Dado o exposto, a próxima seção apresenta os trabalhos que abordam o problema da diversificação em SR propondo algoritmos e métricas de avaliação e, por isso, estão intimamente relacionados com esta proposta. Salienta-se que essas abordagens servirão como ponto de partida e base para o desenvolvimento futuro desta pesquisa.

3. Trabalhos Relacionados

Podem ser identificadas duas 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 diversidade e qualidade/acurácia para gerar uma lista final de recomendação de itens. A segunda linha de soluções tenta incrementar os algoritmos de SR atuais para gerar recomendações de itens mais diversas [Galway 2015].

É importante esclarecer que a diversidade pode ser alcançada em vários níveis. Um deles é a diversidade intra-lista, ou seja, oferecendo a um usuário uma lista diversificada de itens. Outros tipos de diversidade são focados na diversidade inter-lista e na diversidade agregada. Lathia *et al.* (2010) estudam as características temporais da diversidade em SR, enfatizando que não há mecanismo atual para evitar que os usuários recebam as mesmas recomendações uma ou outra vez. Adomavicius e Kwon (2012) introduzem o conceito de diversidade agregada como oferecendo diversas recomendações para todos os usuários. Eles ressaltam que a diversidade agregada não é alcançada através da diversidade individual, por exemplo, se todos os usuários obtiverem a mesma lista diversificada de recomendações, o resultado é uma diversidade individual elevada, mas baixa diversidade agregada.

Ziegler *et al.* (2005) apresentam o método de diversificação de tópicos, que se destina a equilibrar e diversificar listas de recomendações personalizadas 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 existente. O objetivo do algoritmo é reclassificar a lista de entrada e obter uma lista final (*top-N*) diversificada. Aliado a isso eles propõem a métrica ILS (*Intra-List Similarity*) na qual maiores valores indicam menor diversidade. Ziegler et al. salientam que uma característica interessante dessa métrica é a insensibilidade à permutação, ou seja, que um rearranjo dos elementos na lista não afetaria a medida final ILS. No entanto, Vargas, S. S. (2012) resalta que isso pode ser uma limitação considerável, pois os usuários não navegam necessariamente até o final da lista e que a ordem com a qual os itens são apresentados pode influenciar fortemente a utilidade prática da recomendação. A avaliação do método é realizada utilizando dados de recomendação de livros com

testes *off-line* e *on-line*. Os testes *off-line* são destinados a compreender o impacto da diversificação de tópicos em métricas de acurácia. Já os testes *on-line* são destinados a entender como o método afetava a satisfação real dos usuários. Os autores descobriram que, embora o aumento da diversidade prejudique a acurácia, melhora a satisfação dos usuários.

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 *top-N* 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. É por isso que os autores propõem novos métodos de *raking* que podem controlar as perdas de precisão, são eles: padrão, popularidade de item, valor de classificação reverso previsto, classificação média de item, absorção absoluta do item e absorção relativa do item. Os autores realizaram testes *off-line* com dois conjuntos de dados: MovieLens e Netflix. Os cinco métodos de *ranking* foram avaliados por meio de três técnicas de filtragem colaborativa: baseada em usuários, baseada em itens e fatoração de matrizes. Cada *ranking* foi medido em termos de precisão em *top-N* e diversidade em *top-N* (diversidade agregada). Os autores descobriram que todas as abordagens de *ranking* sacrificavam a precisão para ganhar diversidade. A chave é então encontrar um limite que ofereça um alto ganho de diversidade com perda de precisão tolerável.

Vargas, S. S. (2012) identificou uma oportunidade na adaptação das métricas e das técnicas de diversidade aplicadas na área de Recuperação de Informações (RI) para SR, dado que a recomendação pode ser vista como uma tarefa de RI. O autor propõe o conceito: espaço de aspecto. O espaço de aspecto serve como um meio para traduzir noções equivalentes entre RI e SR, especificamente: a similaridade de documento é equivalente à similaridade de item e as intenções de consulta são análogas aos aspectos de perfil de usuário. Com essa analogia, técnicas e métricas associadas à diversidade em RI podem ser facilmente ajustadas para os SR. Para mostrar a aplicação do espaço de aspecto, Vargas, S. S. (2012) adapta o algoritmo IA-Select, que serve para diversificar resultados de pesquisa em RI [Agrawal et al. 2009], para diversificar os resultados em SR. O autor avalia o comportamento do algoritmo de utilizando o conjunto de dados MovieLens 100k. Como *baseline*, são utilizados dois algoritmos de filtragem colaborativa: usuário-usuário e fatoração de matrizes. Os algoritmos de diversificação reclassificam os 500 melhores itens retornados pelo SR *baseline*. São realizados testes para cenários de espaço de aspecto implícitos e explícitos. É mostrado que o algoritmo de diversificação funciona melhor do que os *baselines* não diversificados.

Zhang, M. e Hurley (2009) propõem um novo algoritmo de recomendação de filtragem colaborativa que aumenta a probabilidade de recomendar itens que sejam novos e relevantes. Os autores explicam que é improdutivo diversificar os resultados dos SR tradicionais já que se sabe que as recomendações geradas tendem a ser tendenciosas em relação a itens não novos. Para obter mais itens inovadores, os autores sugerem que é melhor oferecer recomendações dos *clusters* individuais dentro do perfil do usuário e não o perfil do usuário como um todo. O objetivo é aumentar a probabilidade de recomendar novos itens que possam cobrir a gama de preferências do usuário. Para tanto, eles exploram uma série de técnicas de particionamento de perfil de

usuário, tais como: maximização da similaridade intra-cluster, particionamento de grafo, k-means e outros. Após identificar os *clusters* de preferência do usuário, esses são classificados de acordo com a novidade média dos itens. Apenas *k clusters* com a maior novidade agregada são usados para fazer recomendações. Os autores propõem uma nova metodologia de avaliação que pode medir a capacidade do SR de oferecer resultados diversificados em itens relevantes, independentemente de sua novidade. Eles avaliam seu algoritmo no conjunto de dados MovieLens para mostrar que seu algoritmo consegue remover a tendência para itens não inovadores com baixo custo de precisão.

Nessa mesma linha, Vargas, Saúl e Castells (2013) particionam o perfil do usuário em sub perfis usando informações conhecidas sobre categorias no domínio do item. Em seguida, eles geram recomendações de itens para cada sub perfil. Para gerar recomendações para sub perfis com métodos de filtragem colaborativa, os autores analisam diferentes possibilidades, tais como: a similaridade do sub perfil deve ser calculada apenas com outros sub perfis ou com perfis completos. Depois que as recomendações são geradas, o desafio é combinar os resultados e obter uma lista final de recomendações conscientes da diversidade. Para tanto, os autores utilizam uma versão adaptada do algoritmo de diversificação xQuAD. A versão original desse algoritmo (para RI) é modificada com base na ideia de espaços de aspecto apresentados por Vargas, S. S. (2012). Em seguida, o método de diversificação é ainda adaptado para considerar sub perfis de usuários e não o perfil completo. Os autores realizam testes com o conjunto de dados MovieLens 1M e o conjunto de dados Last.fm mostrando que sua proposta atinge resultados competitivos.

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 de 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.

Como uma abordagem diferente, Said *et al.* (2012) propõe uma técnica de filtragem colaborativa de vizinhos mais recente para aumentar a serendipidade e a diversidade. Esta técnica recomenda itens que não gostam de usuários que são os menos parecidos com o usuário alvo. Através de experiências com o conjunto de dados 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.

Retomando a classificação das duas linhas de pesquisa apresentadas no início da seção, os trabalhos apresentados podem ser categorizados conforme a Tabela 1 a seguir.

Tabela 1. Categorização das abordagens em cada técnica

Pós-filtragem	Incremento de algoritmos tradicionais de SR
[Ziegler et al. 2005]	[Zhang 2009] [Zhang and Hurley 2009]
[Adomavicius and Kwon 2009]	[Vargas and Castells 2013]
[Vargas 2012]	[Said et al. 2012]

As soluções propostas de ambas as linhas de pesquisa podem ser utilizadas em conjunto para criar SR conscientes de diversidade: a saída do algoritmo de recomendação de diversificação aprimorado poderia servir como entrada para a abordagem de diversificação pós-filtragem. Uma abordagem combinada parece ser uma aproximação ideal: (i) usar uma abordagem de pós-filtragem sozinha se o conjunto de itens candidatos não for suficientemente diversificado pode gerar um resultado sub ótimo como apontado por Zhang, F. (2009); e (ii) aprimorar um algoritmo de SR tradicional para gerar recomendações diversas, mas classificar isso por relevância também pode produzir resultados sub ótimos, conforme evidenciado por Zhang, M. e Hurley (2009). Portanto, isso motiva esta pesquisa, cuja proposta será apresentada na seção a seguir.

4. Abordagem

Este trabalho propõe uma abordagem de recomendação diversificada aplicada no domínio de cidades inteligentes, levando em consideração o balanceamento entre qualidade e diversidade. Com isso, acredita-se que seja possível resolver o problema da “bolha de filtro” e aumentar a satisfação do usuário, ou seja, com boa acurácia de predição de avaliação e de forma diversa. A Figura 1 apresenta a generalização da proposta e o domínio de aplicação.

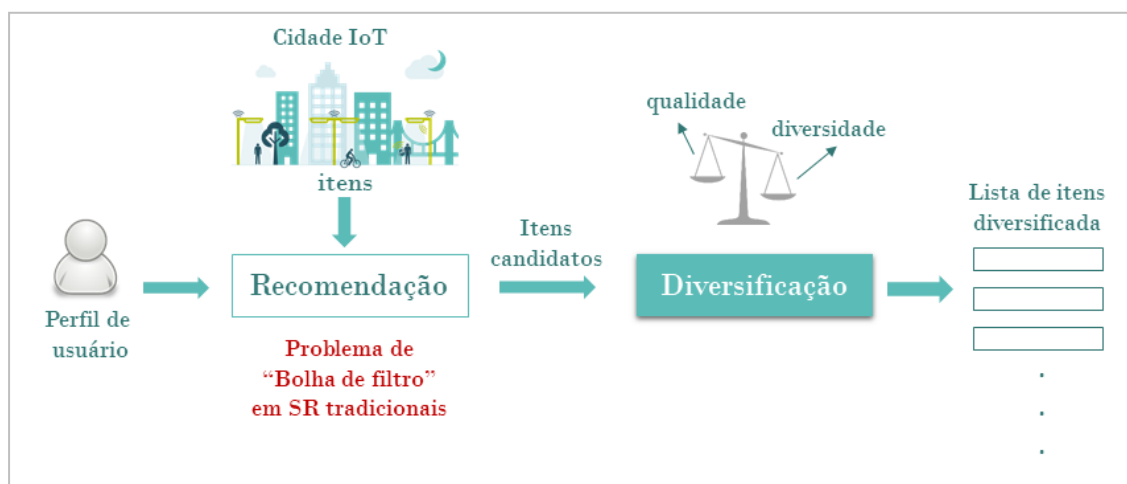


Figura 1. Generalização da proposta e domínio de aplicação

Para atingir o objetivo acima, serão combinadas técnicas de diversificação baseadas em pós-filtragem e baseadas no aprimoramento de algoritmos tradicionais de SR em uma abordagem híbrida, combinando as vantagens de cada uma, a fim de obter elevada acurácia e, ao mesmo tempo, elevada diversidade.

Na Figura 1, “Recomendação” representa um algoritmo de SR tradicional baseado em filtragem colaborativa (por exemplo fatoração de matrizes), que recebe itens da cidade inteligente, e que seria aprimorado para fornecer recomendações pré diversificadas (itens candidatos). Essas recomendações, então, servem de entrada para a etapa “diversificação”, pós-filtragem que visa reordenar o ranking e entregar ao usuário uma lista altamente diversificada e, ao mesmo tempo, com alta qualidade (acurácia). Isso é importante dado que ajuda o usuário a explorar seus gostos e preferências, bem como amplia seus pontos de vista, capacidade de opinião e satisfação.

Para fins de experimentação, inicialmente serão extraídos dados da cidade inteligente. Em seguida, será aplicada a abordagem híbrida de recomendação diversificada. Com isso, num primeiro momento, pretende-se realizar uma avaliação experimental do tipo experimento *off-line*, na qual serão analisadas acurácia de predição de avaliação e diversidade; e, em seguida, será realizada uma avaliação de relevância estatística. Para medir a diversificação serão empregadas medidas de serendipidade e cobertura. Vislumbra-se, também, a realização de experimentos *online* para verificar a satisfação do usuário. A ideia se resume em perguntar para o usuário, por meio de um questionário, o que ele está achando das recomendações e do sistema.

Em Março de 2016 foi inaugurado o *Smart City Innovation Center*, uma parceria entre a PUCRS e a Huawei¹ (grupo empresarial chinês que controla mais de 15 subsidiárias do setor de telecomunicações). Isso se mostra como possibilidade de implantação do protótipo na cidade de Porto Alegre. Nessa perspectiva, também será considerado o portal *datapoa*² para aquisição de dados. Esse portal conta com dados em diferentes formatos (majoritariamente em CSV e JSON), sobre transporte e mobilidade, geolocalização de locais e serviços, meio ambiente, dentre outros. Se for necessário, esses dados podem ser complementados com APIs de redes sociais tais como o Facebook e o FourSquare, por exemplo.

5. Conclusão

Este artigo, inicialmente, apresentou um estudo abrangente sobre o tema de diversificação em sistemas de recomendação. A partir dele, foram identificadas duas linhas de abordagem. A primeira delas é baseada em pós-filtragem, isto é, a diversificação é feita somente após a geração da recomendação (itens candidatos), logo se o conjunto de itens candidatos não for suficientemente diversificado pode gerar um resultado sub ótimo. A segunda linha diz respeito a modificação de algoritmos de recomendação de forma que esses já produzam, como saída final, uma recomendação diversificada, entretanto, aprimorá-los, mas classificar por relevância também pode produzir resultados sub ótimos.

A partir disso, foi proposta uma abordagem híbrida para a diversificação de recomendação, combinando as potencialidades de cada uma das linhas de abordagem com vistas à maximização da diversidade e à minimização de perdas em acurácia sendo, essa, a principal contribuição deste trabalho. Acredita-se fortemente que a abordagem contribuirá para amenizar o efeito de “bolha de filtro”, contribuindo para uma melhor

¹ <http://www.huawei.com/br/>

² <http://www.datapoa.com.br/dataset>

experiência do usuário e possibilitando-o interagir com diferentes opiniões, pontos de vista, dentre outros.

Como trabalhos futuros pode-se citar: a realização de uma ampla e contundente revisão sistemática, a partir deste estudo inicial, que permitirá a escolha dos algoritmos a serem implementados. Também, a realização dos experimentos com e sem usuários, conforme relatado na seção de proposta.

Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, e pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

Referências

- Adomavicius, G., Huang, Z. e Tuzhilin, A. (2008). *Personalization and Recommender Systems*.
- Adomavicius, G. e Kwon, Y. (2009). Toward More Diverse Recommendations: Item Re-Ranking Methods for Recommender Systems. In *Proceedings of the 19th Workshop on Information Technology and Systems*.
- Adomavicius, G. e Kwon, Y. (2012). Diversity Using Ranking-Based Techniques. *IEEE TRANSACTIONS ON KNOWLEDGE AND DATA ENGINEERING*, v. 24, n. 5, p. 896–911.
- Adomavicius, G., Sankaranarayanan, R., Sen, S. e Tuzhilin, A. (1 jan 2005). Incorporating contextual information in recommender systems using a multidimensional approach. *ACM Transactions on Information Systems*, v. 23, n. 1, p. 103–145.
- Agrawal, R., Gollapudi, S., Halverson, A. e Ieong, S. (2009). Diversifying search results. In *Proceedings of the Second ACM International Conference on Web Search and Data Mining - WSDM '09*. ACM Press.
- Berners-Lee, T., Hendler, J. e Lassila, O. (2001). The Semantic Web A new form of Web content that is meaningful to computers will unleash a revolution of new possibilities.
- Chen, J., Liu, Y., Hu, J., He, W. e Li, D. (2013). A novel framework for improving recommender diversity. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, v. 8178 LNAI, p. 129–138.
- Chen, S., Ma, B. e Zhang, K. (2009). On the similarity metric and the distance metric. *Theoretical Computer Science*, v. 410, n. 24–25, p. 2365–2376.
- Coden, A., Gruhl, D., Lewis, N., et al. (2014). *Semantic Web Evaluation Challenge*. v. 475
- Dey, A. K. (28 fev 2001). Understanding and Using Context. *Personal and Ubiquitous Computing*, v. 5, n. 1, p. 4–7.
- Dourish, P. (2004). What we talk about when we talk about context. *Personal and ubiquitous computing*, v. 8, n. 1, p. 19–30.

- Galway, N. U. I. (2015). XPLODIV: DIVERSIFICATION APPROACH FOR RECOMMENDER SYSTEMS.
- Ge, M., Delgado-Battenfeld, C. e Jannach, D. (2010). Beyond Accuracy: Evaluating Recommender Systems by Coverage and Serendipity. In *Proceedings of the fourth ACM conference on Recommender systems - RecSys '10*. ACM Press.
- Herlocker, J. L., Konstan, J. A., Terveen, L. G. e Riedl, J. T. (1 jan 2004). Evaluating collaborative filtering recommender systems. *ACM Transactions on Information Systems*, v. 22, n. 1, p. 5–53.
- Holman, W. e Jenkins, J. (2010). Google and the Search for the Future. <https://www.wsj.com/articles/SB10001424052748704901104575423294099527212>,
- Hurley, N. e Zhang, M. (1 mar 2011). Novelty and Diversity in Top-N Recommendation -- Analysis and Evaluation. *ACM Transactions on Internet Technology*, v. 10, n. 4, p. 1–30.
- Jannach, D. e Adomavicius, G. (2016). Recommendations with a Purpose. In *Proceedings of the 10th ACM Conference on Recommender Systems - RecSys '16*. ACM Press.
- Kapoor, K., Kumar, V., Terveen, L., Konstan, J. A. e Schrater, P. (2015). “I like to explore sometimes”. In *Proceedings of the 9th ACM Conference on Recommender Systems - RecSys '15*. ACM Press.
- Knijnenburg, B. P., Sivakumar, S. e Wilkinson, D. (2016). Recommender Systems for Self-Actualization. In *Proceedings of the 10th ACM Conference on Recommender Systems - RecSys '16*. ACM Press.
- Kunaver, M. e Poržl, T. (maio 2017). Diversity in recommender systems - A survey. *Knowledge-Based Systems*, v. 123, p. 154–162.
- Lathia, N., Hailes, S., Capra, L. e Amatriain, X. (2010). Temporal diversity in recommender systems. In *Proceeding of the 33rd international ACM SIGIR conference on Research and development in information retrieval - SIGIR '10*. . ACM Press.
- Lemire, D., Downes, S. e Paquet, S. (2008). Diversity in open social networks. *Published Online*,
- McNee, S. M., Riedl, J. e Konstan, J. a (2006). Being accurate is not enough. In *CHI '06 extended abstracts on Human factors in computing systems - CHI EA '06*. ACM Press.
- McSherry, D. (2002). Diversity-Conscious Retrieval. In *Proceedings of the 6th European Conference on Advances in Case-Based Reasoning*. , ECCBR '02. Springer-Verlag.
- Nam, T. e Pardo, T. A. (2011). Conceptualizing smart city with dimensions of technology, people, and institutions. In *Proceedings of the 12th Annual International Digital Government Research Conference on Digital Government Innovation in Challenging Times - dg.o '11*. ACM Press.
- Nehring, K. e Puppe, C. (2002). A Theory of Diversity. *Econometrica*, v. 70, n. 3, p. 1155–1198.

- Pariser, E. (2012). *The Filter Bubble: How the New Personalized Web is Changing what We Read and how We Think*. Penguin Books.
- Patil, G. P. e Taillie, C. (1982). Diversity as a Concept and its Measurement. *Journal of the American Statistical Association*, v. 77, n. 379, p. 548–561.
- Resnick, P., Iacovou, N., Suchak, M., Bergstrom, P. e Riedl, J. (1994). GroupLens : An Open Architecture for Collaborative Filtering of Netnews. *Proceedings of the 1994 ACM conference on Computer supported cooperative work*, p. 175–186.
- Ricci, F., Rokach, L., Shapira, B. e Kantor, P. B. (2011). *Recommender Systems Handbook*. 1st. ed. Boston, MA: Springer US.
- Said, A., Kille, B., Jain, B. e Albayrak, S. (2012). Increasing Diversity Through Furthest Neighbor-Based Recommendation. *In Proceedings of the fifth ACM International Conference on Web Search and Data Mining*, p. 1–4.
- Vargas, S. e Castells, P. (2011). Rank and relevance in novelty and diversity metrics for recommender systems. *In Proceedings of the fifth ACM conference on Recommender systems - RecSys '11*. ACM Press.
- Vargas, S. e Castells, P. (2013). Exploiting the Diversity of User Preferences for Recommendation. *Proceedings of the 10th Conference on Open Research Areas in Information Retrieval*, p. 129–136.
- Vargas, S. S. (2012). Novelty and Diversity Evaluation and Enhancement in Recommender Systems. Universidad Autónoma de Madrid.
- Weiser, M. (1 jul 1993). Some computer science issues in ubiquitous computing. *Communications of the ACM*, v. 36, n. 7, p. 75–84.
- Zhang, F. (nov 2009). Improving recommendation lists through neighbor diversification. *In 2009 IEEE International Conference on Intelligent Computing and Intelligent Systems*. IEEE.
- Zhang, M. e Hurley, N. (2009). Novel Item Recommendation by User Profile Partitioning. *In 2009 IEEE/WIC/ACM International Joint Conference on Web Intelligence and Intelligent Agent Technology*. IEEE.
- Zheng, W., Wang, X., Fang, H. e Cheng, H. (2012). Coverage-based Search Result Diversification. *Inf. Retr.*, v. 15, n. 5, p. 433–457.
- Ziegler, C.-N., McNee, S. M., Konstan, J. A. e Lausen, G. (2005). Improving recommendation lists through topic diversification. *In Proceedings of the 14th international conference on World Wide Web - WWW '05*. ACM Press.