

Recomendação não personalizada baseada em Cobertura Máxima

Nícollas Silva¹, Adriano César¹, Fernando Mourão², Leonardo Rocha²

¹ Universidade Federal de Minas Gerais, Brazil
ncsilvaa@gmail.com, adrianoc@dcc.ufmg.br

² Universidade Federal de São João del-Rei, Brazil
fhmourao@ufsj.edu.br, lcrocha@ufsj.edu.br

Abstract. Atualmente, os Sistemas de Recomendação (SsR) estão tão focados em agradar os usuários já existentes no domínio, que acabam dando pouca relevância a uma fase talvez mais importante sob a lógica de negócio: a aquisição de novos usuários. Estratégias de recomendação não personalizadas acabam cada vez mais negligenciadas na literatura. Normalmente, estas estratégias focam em recomendar itens mais populares, mais recentes, mais recorrentes ou mais bem avaliados. Tais abordagens partem da premissa que o consumo dos usuários é, em geral, enviesado por uma dessas dimensões nos cenários em que SsR são aplicáveis. Entretanto, tais premissas não são válidas para o consumo de nichos, em que usuários se interessam por itens diferentes do gosto comum de uma população. Neste intuito, este trabalho tem por objetivo validar a aplicabilidade da Cobertura Máxima, um problema NP-Completo, em SsR sobre os níveis de novidade, diversidade e serendipidade. O pressuposto dessa abordagem é que a probabilidade de um usuário qualquer encontrar um item de sua preferência aumenta devido a diversidade de gostos dos usuários do sistema, que leva a recomendações inusitadas. De fato, os resultados encontrados apresentam em média um ganho de 5,5% em novidade, 18% em diversidade e 60% em serendipidade quando comparada as estratégias de consumo de massa (i.e., itens mais populares ou mais bem avaliados). Além disso, os resultados indicam que os itens recomendados por Cobertura Máxima pertencem a um grupo de itens não populares, o que mostra que a estratégia é capaz de fugir da bolha de itens sempre recomendados. O ganho obtido ao aplicar a estratégia de Cobertura Máxima mostra-se relevante para cenários específicos como *e-commerce*, ou mesmo para solucionar problemas como o de usuários *cold-start* e o efeito da *long-tail*.

Categories and Subject Descriptors: H.3.3 [Retrieval tasks and goals]: Recommender Systems

Keywords: Sistemas de Recomendação, Cobertura Máxima, Novidade, Diversidade, Serendipidade

1. INTRODUÇÃO

Sistemas de Recomendação (SsR) constituem uma das mais importantes ferramentas utilizadas para auxiliar usuários na tomada de decisão em variados cenários reais [Koren et al. 2009]. Atualmente, grande parte dos SsR se preocupam em atender adequadamente aos gostos dos usuários já existentes em um dado sistema através da recomendação personalizada. Entretanto, pouca relevância é dada a uma fase igualmente importante sob a lógica de negócio: a aquisição de novos usuários. Neste caso, tornam-se pertinentes perguntas tais como: *Como apresentar os itens disponíveis no sistema a potenciais usuários quando não se sabe nada sobre estes?*; e *Quais itens de um catálogo de produtos apresentam maior potencial para atrair novos usuários?*. As técnicas de recomendação mais utilizadas para abordar essas questões se baseiam em estratégias não personalizadas, considerando assim o contexto geral do cenário estudado ao invés do passado de cada usuário específico.

As principais estratégias de recomendação não personalizadas utilizadas atualmente exploram informações simples como popularidade dos itens, avaliações positivas ou recência de lançamento [Iskold 2007]. Tais abordagens partem da premissa que o consumo é, em geral, enviesado por uma dessas dimensões nos cenários em que SsR são aplicáveis, permitindo-se atingir alta eficácia de predições

Este trabalho foi parcialmente patrocinado pelo Instituto Nacional de Ciência e Tecnologia para a Web (CNPq no. 573871/2008-6), MASWeb (grant FAPEMIG/PRONEX APQ-01400-14), EUBra-BIGSEA (H2020-EU.2.1.1 690116, Brazil/MCTI/RNP GA-000650/04), CAPES, CNPq e Fapemig.

Copyright©2012 Permission to copy without fee all or part of the material printed in KDMiLe is granted provided that the copies are not made or distributed for commercial advantage, and that notice is given that copying is by permission of the Sociedade Brasileira de Computação.

através de estratégias simples e não supervisionadas. Apesar dessa premissa ser válida para o denominado "consumo de massa", em que usuários consomem itens que despertam interesse em grande parte de uma população, o mesmo não pode ser dito sobre "consumo de nichos", em que usuários se interessam por itens diferentes do gosto comum de uma população. Dessa forma, apresentar apenas itens pertencentes ao consumo de massa a potenciais consumidores de nicho não representaria uma boa estratégia para a aquisição deste tipo de consumidores. Atender adequadamente aos gostos deste tipo de usuário, porém, é de suma importância para diversos cenários, uma vez que o mercado de nicho pode representar mais da metade do lucro em cenários de e-commerce, definindo-se o que se conhece como cauda longa do consumo [Anderson 2006].

Este trabalho tem por objetivo avaliar uma nova estratégia de recomendação não personalizada que visa apresentar a potenciais usuários tanto itens pertencentes ao consumo de massa quanto ao consumo de nichos. Nossa proposta baseia-se na aplicação do famoso problema de Cobertura Máxima a cenários de recomendação [Michael and David 1979]. A estratégia de Cobertura Máxima visa identificar um subconjunto de itens do domínio que são potencialmente relevantes para o maior número de usuários distintos. A premissa dessa abordagem é que recomendar os itens que satisfaçam ao maior número de usuários traz mais diversidade e surpresa a todos os usuários do sistema quando comparada a estratégias de recomendar os itens mais populares ou mais bem avaliados. Além disso, a probabilidade de um usuário específico encontrar pelo menos um item próximo de sua preferência pessoal aumenta devido a estratégia tentar cobrir uma grande diversidade de gostos distintos. Cabe salientar que recomendar itens que atendam ao consumo de massa é considerada uma tarefa fácil, dado o grande volume de informações de consumo disponíveis sobre tais itens. Por outro lado, a recomendação de itens pertencentes ao consumo de nichos é uma tarefa difícil e com grandes implicações para variados cenários, mas ainda em aberto na literatura.

De forma a avaliar a relevância prática das recomendações geradas pela estratégia de Cobertura Máxima, calcula-se os níveis de novidade, diversidade e serendipidade sobre as coleções de filmes do *MovieLens*, através de métricas tradicionais propostas em [Vargas and Castells 2011] e [Zhang et al. 2012]. De fato, os resultados encontrados ao compararmos essas estratégias de recomendação evidenciam o pressuposto dessa nova abordagem. Aplicar a estratégia de Cobertura Máxima tende a trazer mais surpresa aos usuários do domínio, satisfazendo suas distintas preferências. As recomendações geradas apresentam em média um ganho de 5,5% em novidade, 18% em diversidade e 60% em serendipidade quando comparada as estratégias de consumo de massa que recomendam itens mais populares ou mais bem avaliados. Nota-se também, que as recomendações geradas por Cobertura Máxima consistem em itens não populares, contendo em média 18% de itens distintos do gosto comum da população geral. Tais itens são capazes de satisfazer ao consumo de nichos de alguns usuários. Além disso, pode-se notar que mesmo com esses ganhos, a recomendação por Cobertura Máxima não se distancia das demais estratégias quando comparada as métricas clássicas de acurácia. Ressaltamos que as contribuições deste trabalho são particularmente relevantes para estudos aplicados, como na aplicação em cenários no qual o consumo dos usuários está centrado em itens populares. Cabe ainda salientar que não encontramos na literatura trabalhos que abordem os aspectos levantados sobre a aplicabilidade do problema de Cobertura Máxima para recomendações não personalizadas.

2. REFERENCIAL TEÓRICO

Em variados cenários reais de recomendação, como de *e-commerce* [Hinz and Eckert 2010], turismo [Batet et al. 2012] ou filmes [Herlocker et al. 1999], surgiu a necessidade de avaliar não apenas a recomendação personalizada ao usuário. Em sistemas *e-commerce*, por exemplo, os proprietários estão interessados em maximizar o lucro final, aderindo a estratégias de recomendação não personalizada, e não se preocupando com a fidelidade do usuário [Hammar et al. 2013]. Nestes, as técnicas de SsR utilizam estratégias de recorrência, recência e itens mais bem avaliados. De maneira geral, recomendam-se itens que estão relacionados entre si (i.e., quem comprou este, comprou também), ou mesmo os itens mais vendidos recentemente. Em [Hammar et al. 2013], os autores se preocuparam em maximizar a probabilidade dos clientes realizarem compras e utilizaram a estratégia de cobertura

máxima para aumentar a diversidade de produtos aos clientes. Por sua vez, em cenários de filmes, uma dificuldade comum encontra-se em recomendar itens a usuários novos no sistema (i.e., *cold-start*), visto que estes não possuem nenhum histórico de atividades [Schein et al. 2002]. Neste contexto, estratégias de popularidade estão sendo cada vez mais aplicadas na tentativa de apresentar um contexto global do sistema a um usuário que não se tem um histórico de consumo definido.

Em geral, estratégias não personalizadas em SsR, referem-se a recomendadores que não visam somente os usuários finais. As recomendações geradas são independentes dos usuários, de modo que cada usuário recebe as mesmas recomendações [Schafer et al. 1999]. Basicamente, estratégias não personalizadas visam recomendar itens aos usuários com base na opinião geral destes sobre os conteúdos disponíveis. Técnicas não personalizadas são comuns em cenários onde é necessário configurar uma exibição que é vista sem alterações específicas por cada usuário. Por exemplo, as recomendações apresentadas pela *amazon.com*, quando um usuário específico não está logado no sistema, são recomendações não personalizadas que representam um contexto geral, sendo completamente independentes de um usuário específico.

2.1 Popularidade

Recomendadores baseados em popularidade consistem em uma estratégia simples e intuitiva, que sempre recomenda os itens mais populares na coleção de dados, independente do usuário alvo. A popularidade de um item é estimada pelo número de usuários distintos que já consumiram este item no passado. No contexto de filmes, por exemplo, para cada filme do domínio calcula-se a quantidade de usuários distintos que o assistiu. Esta abordagem, embora seja muito simples, tem se mostrado eficiente em algumas aplicações [Bobadilla et al. 2013] e constitui uma das principais técnicas de recomendação não personalizadas alcançando bons resultados.

2.2 Itens mais bem avaliados

Recomendadores baseados em itens mais bem avaliados consistem em outra estratégia simples, que sempre recomenda os mesmos itens independente do usuário alvo. Basicamente, gera um *ranking* de itens ordenados decrescentemente pela média dos *ratings* recebidos por cada item do sistema. O pressuposto dessa abordagem é que os itens mais bem avaliados tendem a interessar vários usuários.

2.3 Cobertura Máxima

No cenário de recomendação, podemos formalizar o problema de Cobertura Máxima da seguinte maneira: dado $U = \{u_1, u_2, \dots, u_m\}$, como o conjunto de usuários do sistema e dado $F = \{S_1, S_2, \dots, S_n\}$ como uma coleção de conjuntos S_i de usuários que consumiram o item i , o objetivo é determinar um subconjunto $F^* = \{S_{i_1}, S_{i_2}, \dots, S_{i_k}\}$ que contém o maior número de usuários distintos possíveis.

MAXIMUM k -COVERAGE

Instância: Conjunto de elementos $U = \{u_1, \dots, u_m\}$, um valor inteiro k e uma coleção de conjuntos $F = \{S_1, \dots, S_n\}$, onde cada conjunto S_i é um subconjunto de U .

Objetivo: Encontrar o subconjunto $F^* \subseteq F$ tal que $|F^*| \leq k$ e o número de elementos cobertos $|\bigcup_{S_i \in F^*} S_i|$ seja maximizado.

De maneira geral, podemos dizer que o objetivo da Cobertura Máxima é encontrar um subconjunto F^* de itens, tal que $|F^*| \leq k$, que maximize o número de usuários distintos atingidos. Em outras palavras, pretendemos encontrar os k filmes que interessaram ao maior número de usuários distintos e recomendá-los aos usuários finais. Note que este problema, não está interessado no passado de consumo de um usuário específico, mas sim de todos os usuários da coleção de dados.

O problema de Cobertura Máxima é um variante do famoso problema de Cobertura de Vértices, bem estudado pela literatura [Alon et al. 2003]. Infelizmente, estes são problemas da classe NP-Completo, e portanto não existe uma solução ótima que possa ser resolvida em tempo polinomial.

Entretanto, usando uma simples heurística gulosa, conforme mostra o Algoritmo 1 que obtém uma aproximação de 63% do número máximo de usuários que podem ser cobertos, conforme mostrado em [Chvatal 1979]. Em alguns cenários menores o algoritmo aproximativo de tempo polinomial, possui um bom desempenho [Feige 1995], conseguindo atingir as soluções ótimas do problema. Este algoritmo é implementado com complexidade temporal de $O(knm)$, sendo k o número de itens encontrados pelo algoritmo, m o número de usuários e n o número de itens.

Algorithm 1 GREEDY-MAX-COVERAGE(U, k, F)

```

1:  $R \leftarrow U$ 
2:  $F^* \leftarrow \emptyset$ 
3: for  $i$  from 1 to  $k$  do
4:    $S \leftarrow \max_{S \in (F \setminus F^*)} |S \cap R|$ 
5:    $F^* \leftarrow F^* \cup \{S\}$ 
6:    $R \leftarrow R \setminus S$ 
7:   if  $|R| = 0$  then
8:     break
9:   end if
10: end for
11: return  $F^*$ 

```

3. PROJETO EXPERIMENTAL

Motivados em analisar a aplicabilidade do problema de Cobertura Máxima em SsR, o projeto de análise experimental está relacionado às dimensões de análise de novidade, diversidade e serendipidade. Primeiramente, são apresentadas as coleções de dados utilizadas na análise. Em seguida, define-se as métricas básicas de novidade, diversidade e serendipidade a serem utilizadas por nossas análises. Por fim, é apresentada a metodologia de avaliação utilizada para analisar os resultados encontrados.

3.1 Coleções de Dados

Dada a relevância destes cenários, selecionamos os conjuntos de dados *MovieLens* 100k e *MovieLens* 1M¹ que foram reunidos pelo *GroupLens* e contém, respectivamente, 100 mil e 1 milhão de *ratings* atribuídos por usuários a filmes de diversas categorias. Ambos são conjuntos de dados explícitos, onde existem *ratings* atribuídos pelos usuários no intervalo de 1 a 5. Em cada conjunto, existem pelo menos vinte *ratings* atribuídos por cada usuário a filmes de seu interesse. Tal abordagem resulta em conjuntos de dados altamente esparsos, conforme mostra a tabela I. Para este trabalho, as bases de dados foram divididas em treino e teste, mantendo a premissa da ordenação temporal do consumo dos itens, com uma distribuição de 70% para treino.

Table I. Bases de dados utilizadas.

Base	Usuários	Itens	Esparsidade
<i>MovieLens 100k</i>	943	1.676	93,67%
<i>MovieLens 1M</i>	6.040	3.952	95,82%

3.2 Métricas de Avaliação

A novidade de uma informação geralmente se refere a quão diferente esta informação é com relação a tudo que tinha sido previamente observado, por um específico usuário, ou por uma comunidade como um todo [Ricci et al. 2011]. Neste trabalho, o conceito de novidade é mensurado por meio da distância entre os itens recomendados e os itens do perfil de cada usuário, definido como distância esperada do perfil (EPD), como proposto no *framework* de [Vargas and Castells 2011]. Vale destacar que a fórmula 1 utilizada considera o conceito de novidade intrinsecamente ligado ao conceito de utilidade (relevância), uma vez que recomendar algo novo que não seja útil ao usuário é uma tarefa fácil. Um item é considerado relevante se a média das avaliações atribuídas a ele for maior ou igual a um limiar mínimo, que pode ser a nota média do usuário ao qual ele está sendo recomendado.

¹Disponíveis em: <<http://www.grouplens.org/node/12>>

$$nov(R|u) = EPD = C' \sum_{i_k \in R, j \in U} disc(k) p(rel|i_n, u) p(rel|j, u) d(i_k, j) \quad (1)$$

Por sua vez, diversidade geralmente se aplica a um conjunto de itens, e está relacionada com o quão diferente os itens são com relação uns aos outros [Ricci et al. 2011]. Em [Vargas and Castells 2011], diversidade é mensurada como a distância média esperada de um item para uma lista de itens (ILD), calculada como o complemento da similaridade dos itens recomendados, como mostra a equação 2.

$$div(R|u) = ILD = \frac{2}{|R|(|R| - 1)} \sum_{i_k \in R, l < k} d(i_k, i_l) \quad (2)$$

Por outro lado, o conceito de serendipidade relacionado a recomendação, é uma forma de mensurar o quão surpreso o usuário ficou com o sucesso das recomendações. Neste trabalho, utiliza-se o *framework* proposto em [Zhang et al. 2012], que calcula serendipidade com base na equação 3. Basicamente, utiliza-se a similaridade de cosseno para medir a similaridade média entre os itens presentes no histórico de um usuário e novas recomendações geradas. Os valores mais baixos indicam que as recomendações desviam do comportamento tradicional de um usuário, e, portanto, trazem maior surpresa.

$$ser = 1 - \sum_{u \in S} \frac{1}{|S||H_u|} \sum_{h \in H_u} \sum_{i \in R_{u,20}} \frac{CosSim(i, h)}{20} \quad (3)$$

Por fim, calcula-se também o número absoluto de acertos (*hits*) gerados pelas estratégias não personalizadas. Para tal, simplesmente verifica-se quantos itens da lista Top-k, gerada pelo recomendador, foram de fato *consumidos* pelos usuários de acordo com as informações retidas no conjunto teste.


3.3 Metodologia de Avaliação

As estratégias de recomendação não personalizadas são aplicadas sobre cada conjunto de dados e são geradas listas de recomendação: *C-list*, com os itens da cobertura máxima; *P-list*, com os itens da popularidade; e *A-list*, com os itens mais bem avaliados. Posteriormente, para cada usuário, são recomendados os k primeiros itens das listas geradas, uma vez que o foco deste trabalho está na tarefa *Top-k*. Para as análises, varia-se o valor de k entre [5, 10, 20, 50, 100] a fim de avaliar o desempenho da recomendação em cenários reais. A metodologia é definida nos seguintes passos:

- (1) Avaliar a semelhança entre os *Top-k* itens presentes nas listas *P-list*, *A-list* e *C-list*.
- (2) Avaliar a acurácia de cada estratégia implementada, no intuito de determinar se os itens recomendados são potencialmente relevantes para os usuários. Calcula-se a taxa de acerto de cada recomendador e encontra-se a taxa de acertos média gerada.
- (3) Avaliar o nível de novidade, diversidade e serendipidade para cada uma das estratégias. Para cada um dos *ranking* obtidos, calcula-se o valor médio de surpresa obtido em cada recomendação *Top-k*, bem como a área sobre a curva (AUC).
- (4) Avaliar o impacto de cobertura máxima nos cenários, verificando os itens recomendados por cada técnica. Procura-se analisar em qual parte da distribuição dos dados os itens recomendados pertencem, a fim de descobrir se a técnica é efetiva para atenuar o problema da *long-tail*.


4. ESTUDO DE CASO

Com base na metodologia de avaliação proposta, primeiramente, calcula-se a porcentagem de itens iguais recomendados pelas estratégias de recomendação não personalizadas. Com o diagrama de Venn, mostrado na Figura 1, pode-se notar que mais de 40% dos itens recomendados são semelhantes em todas as estratégias. Nota-se também que, para ambos os cenários, a estratégia de recomendar os itens mais bem avaliados se assemelha mais de 80% da estratégia de popularidade. Essa observação refere-se ao fato que os itens populares tendem a ser bem avaliados. Por sua vez, nota-se que 45% dos itens recomendados por Cobertura Máxima são diferentes das demais estratégias. Tal fato indica que as técnicas estudadas apresentam resultados distintos que podem ser relevantes para cenários reais.

Fig. 1. Diagrama de Venn para representar a semelhança dos itens recomendados na lista *top-100*.

Em seguida, calcula-se a taxa média de acertos gerada por cada uma das estratégias para cada cenário estudado, considerando as distintas listas *Top-k* propostas. Pode-se notar, com base no resultado mostrado na Figura 2, que a estratégia de popularidade possui uma maior taxa de acertos. Conforme o esperado, tais resultados referem-se ao fato de que recomendar itens populares é uma tarefa fácil, pois os usuários tendem a gostar dos itens mais assistidos pelos demais. Nota-se também que o resultado da estratégia de recomendar itens mais bem avaliados se assemelha muito a de popularidade, visto que os itens recomendados são 80% semelhantes.

Fig. 2. Taxa média de acertos obtidos por ambas as estratégias para os dois cenários.

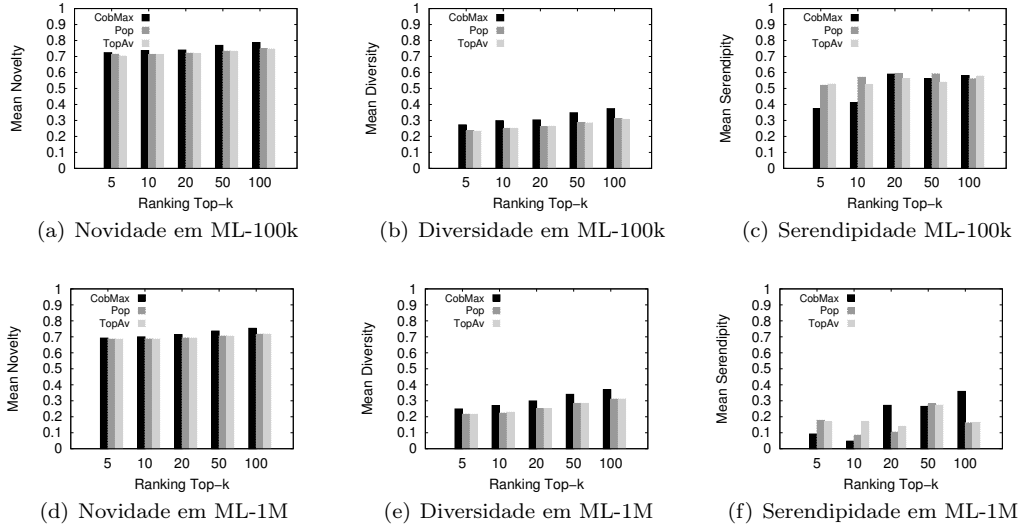


Por fim, foi avaliado as métricas de novidade, diversidade e serendipidade, para as estratégias não personalizadas. A Figura 3 mostra a média dos valores obtidos por cada métrica, criando um contexto global de análise sobre todos as listas de recomendação propostas. Pode-se notar que, em ambos conjuntos de dados, a estratégia de Cobertura Máxima obteve resultados estatisticamente melhores que as demais estratégias, com uma confiança de 95% e um $p\text{-value} = 0,01$ utilizando o teste de *Wilcoxon* para distribuições não normais. A diferença entre as técnicas pode ser observada ao analisarmos a AUC para os *rankings* gerados pelas métricas na recomendação *top-100*. Conforme mostra a Tabela II, nota-se que utilizar a estratégia de Cobertura Máxima tende a trazer mais surpresa aos usuários finais. Para ambos os cenários avaliados, as recomendações geradas obtiveram um ganho considerável, apresentando em média um ganho de 5,5% em novidade, 18% em diversidade e 60% em serendipidade quando comparada as estratégias de consumo de massa. Vale ressaltar que a pequena porcentagem de ganho de novidade está relacionada ao conceito de utilidade presente na métrica, uma vez que os itens populares e mais bem avaliados são também relevantes para os usuários. Tais resultados mostram que, mesmo não sendo uma estratégia muito utilizada na literatura, Cobertura Máxima apresenta resultados potencialmente relevantes para o arcabouço de recomendações não personalizadas.

Table II. AUC de novidade, diversidade e serendipidade, na recomendação *top-100*.

	Coleção	Novidade	Diversidade	Serendipidade
Pop	MovieLens 100k	0.748535	0.311146	0.5605
	MovieLens 1M	0.716321	0.310218	0.162252
Av	MovieLens 100k	0.747797	0.306348	0.578043
	MovieLens 1M	0.717488	0.312109	0.164391
CM	MovieLens 100k	0.786936	0.373318	0.579967
	MovieLens 1M	0.753135	0.369072	0.358536


Fig. 3. Média dos valores de novidade, diversidade e serendipidade para ambas as estratégias.



4.1 Impacto da estratégia de Cobertura Máxima

O impacto de aplicar a estratégia de Cobertura Máxima se torna evidente em cenários cujo consumo dos usuários está fortemente relacionado a itens que despertam interesse em grande parte da população (i.e., consumo de massa). Ao relacionar a popularidade dos itens e o histórico de consumo dos usuários no domínio estudado, como mostram as Figuras 4(a) e 4(b), nota-se um efeito similar a *long-tail*² causado pelo consumo de massa. Em geral, a grande maioria dos usuários do domínio consomem poucos itens e estes itens consumidos são os populares. Neste contexto, recomendações relacionadas ao consumo de massa não representariam uma boa estratégia para a aquisição de potenciais consumidores de nichos, visto que estes recomendadores ficariam presos a recomendar itens da *cabeça* da distribuição (i.e., itens muito consumidos).

Fig. 4. Distribuições geradas pelas coleções de dados utilizadas.



Entretanto, ao avaliar se os itens recomendados por Cobertura Máxima pertencem a *cabeça* ou a *cauda* da distribuição de popularidade, nota-se que tal estratégia é de fato válida para o consumo de nichos. Por meio do cálculo da derivada segunda sobre a distribuição de popularidade encontra-se o *joelho* da distribuição na qual pode-se dividir o conjunto de itens em 12% para a *cabeça* e 88% para a *cauda*. Desse modo, verifica-se que em torno de 21% e 15% dos itens recomendados por Cobertura Máxima, para os cenários do ML-100k e ML-1M, respectivamente, pertencem a *cauda* da distribuição. Em outras palavras, recomendações geradas por Cobertura Máxima tendem a atenuar o problema da *long-tail*, trazendo benefícios para diversas aplicações reais por satisfazer o consumo de nichos ao recomendar itens não populares.

²Uma distribuição de potência relativa ao consumo dos usuários, que tendem a consumir muitos itens populares.

5. CONCLUSÕES & TRABALHOS FUTUROS

Este trabalho teve por objetivo avaliar a aplicabilidade da estratégia de Cobertura Máxima quando aplicada a tarefa de recomendação não personalizada, a fim de atender adequadamente as preferências de usuários que se interessam por itens diferentes do gosto comum da população (i.e., consumo de nichos). No intuito de avaliar a relevância prática da estratégia, foi calculado os níveis de novidade, diversidade e serendipidade sobre as coleções de filmes do *MovieLens* e comparado os resultados encontrados com os das estratégias de recomendar itens mais populares e mais bem avaliados (i.e., consumo de massa). De maneira geral, as recomendações geradas apresentam em média um ganho de 5,5% em novidade, 18% em diversidade e 60% em serendipidade quando comparada as estratégias de consumo de massa que recomendam itens mais populares ou mais bem avaliados. Nota-se que as recomendações geradas por Cobertura Máxima consistem também em itens não populares, contendo em média 18% de itens distintos do gosto comum da população geral. Tais itens devem ser recomendados para cenários onde almeja-se satisfazer as distintas preferências de potenciais usuários do domínio, satisfazendo o consumo de nichos. Além disso, pode-se notar que mesmo com esses ganhos, a recomendação por Cobertura Máxima não se distancia das demais estratégias quando comparada as métricas clássicas de acurácia.

Dessa forma, pode-se dizer que estes resultados respondem as questões levantadas por este trabalho, ressaltando a relevância de se apresentar itens distintos ao gosto comum da população. Os resultados também evidenciam a necessidade de melhor analisar a estratégia de Cobertura Máxima dentro do contexto de SsR. Pretendemos, futuramente, combiná-la a outras estratégias comuns na literatura, ou mesmo adicionar restrições que sejam capaz de melhorar a taxa de acertos dessa estratégia, bem como os índices de surpresa.

REFERENCES

- ALON, N., AWERBUCH, B., AND AZAR, Y. The online set cover problem. In *Proceedings of the thirty-fifth annual ACM symposium on Theory of computing*. ACM, pp. 100–105, 2003.
- ANDERSON, C. *The long tail: Why the future of business is selling less of more*. Hyperion, 2006.
- BATET, M., MORENO, A., SÁNCHEZ, D., ISERN, D., AND VALLS, A. Turist@: Agent-based personalised recommendation of tourist activities. *Expert Systems with Applications* 39 (8): 7319–7329, 2012.
- BOBADILLA, J., ORTEGA, F., HERNANDO, A., AND GUTIÉRREZ, A. Recommender systems survey. *Knowledge-Based Systems* vol. 46, pp. 109–132, 2013.
- CHVATAL, V. A greedy heuristic for the set-covering problem. *Mathematics of operations research* 4 (3): 233–235, 1979.
- FEIGE, U. A threshold of $\ln n$ for approximating set cover. *Journal of the ACM*, 1995.
- HAMMAR, M., KARLSSON, R., AND NILSSON, B. J. Using maximum coverage to optimize recommendation systems in e-commerce. In *Proceedings of the 7th ACM conference on Recommender systems*. ACM, pp. 265–272, 2013.
- HERLOCKER, J. L., KONSTAN, J. A., BORCHERS, A., AND RIEDL, J. An algorithmic framework for performing collaborative filtering. In *Proceedings of the 22nd annual international ACM SIGIR conference on Research and development in information retrieval*. ACM, pp. 230–237, 1999.
- HINZ, J. D. O. AND ECKERT, D.-K. J. The impact of search and recommendation systems on sales in electronic commerce. *Business & Information Systems Engineering* 2 (2): 67–77, 2010.
- ISKOLD, A. The art, science and business of recommendation engines. *Retrieved April* vol. 5, pp. 2012, 2007.
- KOREN, Y., BELL, R., AND VOLINSKY, C. Matrix factorization techniques for recommender systems. *Computer* (8): 30–37, 2009.
- MICHAEL, R. G. AND DAVID, S. J. Computers and intractability: a guide to the theory of np-completeness. *WH Free. Co., San Fr.*, 1979.
- RICCI, F., ROKACH, L., AND SHAPIRA, B. *Introduction to recommender systems handbook*. Springer, 2011.
- SCHAFER, J. B., KONSTAN, J., AND RIEDL, J. Recommender systems in e-commerce. In *Proceedings of the 1st ACM conference on Electronic commerce*. ACM, pp. 158–166, 1999.
- SCHEIN, A. I., POPESCU, A., UNGAR, L. H., AND PENNOCK, D. M. Methods and metrics for cold-start recommendations. In *Proceedings of the 25th annual international ACM SIGIR conference on Research and development in information retrieval*. ACM, pp. 253–260, 2002.
- VARGAS, S. AND CASTELLS, P. Rank and relevance in novelty and diversity metrics for recommender systems. In *Proceedings of the fifth ACM conference on Recommender systems*. ACM, pp. 109–116, 2011.
- ZHANG, Y. C., SÉAGHDHA, D. Ó., QUERCIA, D., AND JAMBOR, T. Auralist: introducing serendipity into music recommendation. In *Proceedings of the fifth ACM international conference on Web search and data mining*. ACM, pp. 13–22, 2012.