

# Combinando modelos de diversificação complementares para recomendações personalizadas de pontos de interesse\*

Heitor Werneck<sup>1</sup>, Nícollas Silva<sup>2</sup>, Leonardo Rocha<sup>1</sup>

<sup>1</sup> DCOMP/UFSJ - São João del-Rei, MG, Brasil

<sup>2</sup> DCC/UFMG - Belo Horizonte, MG, Brasil

werneck@aluno.ufsj.edu.br, ncsilvaa@dcc.ufmg.br, lcrocha@ufsj.edu.br

**Abstract.** Nowadays, Location-Based Social Networks (LBSNs) have become an important tool to help people explore new places – a.k.a., points of interest (POIs). In this sense, this work: (1) performs a systematic mapping of the most recent approaches applied in LBSN; (2) presents a solution to the traditional accuracy-diversity trade-off of any recommender; and (3) provides such a solution through a reproducible package that also includes all the systematic mapping tools and several models of recommendation of POIs. Our solution is named DisCovER and it becomes a new benchmark for the scenario as it outperforms all state-of-the-art methods.

**Resumo.** Atualmente, Redes Sociais Baseadas em Localização (LBSNs) têm se tornado uma ferramenta importante para ajudar pessoas a explorarem novos lugares – a.k.a., pontos de interesse (POIs). Neste sentido, este trabalho: (1) faz um mapeamento sistemático das abordagens mais recentes aplicadas em LBSN; (2) apresenta uma solução para o trade-off clássico entre acurácia-diversidade de qualquer recomendador; e (3) disponibiliza tal solução por meio de um pacote reprodutível que também inclui todas as ferramentas do mapeamento sistemático e diversos modelos de recomendação de POIs. Nossa solução é chamada DisCovER e apresenta-se como um novo benchmark para o cenário uma vez que apresenta resultados superiores a todos os métodos estado-da-arte.

## 1. Introdução

Redes sociais baseadas na localização do usuário (i.e., Location-Based Social Networks - LBSNs) tais como Foursquare e Yelp se tornaram ferramentas importantes para pessoas interessadas em explorar novos pontos de interesse (POIs), tais como museus, restaurantes, etc. Sistemas de Recomendação (SsR) têm sido utilizado por essas aplicações para prestar melhores serviços, tanto para os usuários quanto para os responsáveis por POIs [Liu et al. 2013]. Semelhante aos domínios de recomendação tradicionais, lidar com o *trade-off* entre precisão e diversidade é um grande desafio para fornecer recomendações úteis sobre LBSNs. No entanto, este domínio acrescenta uma dimensão igualmente relevante a este desafio: a distância geográfica entre usuários e POIs. Além de entender como as características dos serviços oferecidos por cada POI se adaptam às necessidades do usuário, perceber até onde os usuários estão dispostos a se deslocar para atender a essas necessidades é de extrema relevância.

---

\*Esse trabalho foi parcialmente financiado por CNPq, CAPES, FINEP e Fapemig

Por meio de uma extensa revisão e mapeamento sistemático da literatura, observamos que esforços recentes de recomendações de POIs vêm desconsiderando a complementaridade entre as dimensões de categorias e de localização geográfica dos POIs no processo de diversificação [Han and Yamana 2017, Qian et al. 2019] ou, quando a consideram, não conseguem combiná-las adequadamente [Lu and Tintarev 2018]. Deste modo, este trabalho discute quatro características inerentes aos domínios POI que esforços anteriores não conseguiram reconhecer: (1) categorias e localizações de POIs são dimensões complementares de diversificação que devem ser abordadas simultaneamente; (2) a diversidade é um conceito complexo que deve ser modelado por modelos distintos e não ortogonais; (3) usuários distintos têm diferentes vontades e vieses de locomoção para atender às suas necessidades; (4) recomendação de POIs é uma tarefa multiobjetivo.

Sumarizamos as principais contribuições deste trabalho de iniciação científica:

- Um mapeamento sistemático da literatura de recomendação de POI visando consolidar um quadro atualizado das principais pesquisas realizadas recentemente nesta área e destacando as principais limitações, características centrais e direções que estamos seguindo como comunidade. Apresentado na seção 2;
- Uma nova estratégia para recomendação de POI, o *DisCovER*, capaz de explorar simultaneamente dimensões complementares de diversificação (isto é, categórica e geográfica) mantendo alta precisão. Apresentado na seção 3;
- Uma abordagem para personalização do *DisCovER* que aplica níveis distintos de diversificação categórica e geográfica para cada usuário. Apresentado na seção 4;
- Uma avaliação experimental detalhada e cientificamente rigorosa, comparando o *DisCovER* com vários algoritmos estado da arte. Consideramos, simultaneamente, várias classes de métricas relacionadas à precisão, novidade e diversidade. Isso corresponde a um avanço para esse tipo de pesquisa, pois a maioria dos trabalhos considera apenas uma classe de métricas. Apresentado na seção 5;
- Um framework que permite a reprodução de nossos experimentos e resultados. Além de incluir todas as linhas de base mais recentes da literatura, é possível estender o framework e utilizá-lo para a avaliação de novos sistemas de recomendação de POI. Apresentado na seção 6.

Além disso, esta iniciação científica resultou em 5 artigos tendo o bolsista como o autor principal:

1. Dois artigos no WebMedia 2020 (A3) [Werneck et al. 2020a, Werneck et al. 2020b];
2. Um artigo no periódico Information Systems 2021 (A1) [Werneck et al. 2021b];
3. Um artigo no periódico Expert Systems With Applications 2021 (A1) [Werneck et al. 2021a];
4. Um artigo no periódico Information Systems 2022 (A1) [Werneck et al. 2022].

Todas as implementações realizadas na iniciação científica, bem como as execuções dos experimentos foram realizadas pelo discente Heitor Werneck, sob a orientação do docente Leonardo Rocha. A concepção do projeto e as análises de resultados foram feitas em conjunto, discente e docente, com a colaboração do aluno de doutorado do Programa de Pós-Graduação do DCC/UFMG, Nícollas Silva.

## 2. Revisão da Literatura & Mapeamento Sistemático

O surgimento de redes sociais baseadas em localização (LBSNs – Location-based social networks) nos últimos anos impulsionou melhorias nos sistemas de recomendação para uma tarefa nova e específica: a recomendação de pontos de interesse (POI). Apesar de todos os avanços contundentes observados recentemente, a área ainda carece de uma visão atualizada e consolidada sobre as principais limitações, pressupostos comuns e rumos que estamos seguindo como comunidade. Assim, buscamos fornecer um panorama atualizado da recomendação POI, identificando esforços, resultados, contribuições e limitações relevantes. Em suma, nosso objetivo é responder as seguintes questões de pesquisa:

*QP1: Quais são os problemas, métodos e tipos de dados mais abordados pelos recentes estudos sobre recomendação de POI?*

*QP2: Quais são as principais dimensões de qualidade utilizadas pelos estudos recentes para avaliar modelos de recomendação de POI?*

*QP3: Quais são as métricas e bases de dados mais utilizadas para avaliar modelos de recomendação de POI atualmente?*

Selecionamos 74 artigos relevantes publicados nos anos de 2017, 2018, e 2019 nas principais conferências e revistas da área. Usamos as seguintes *strings* de busca em diversos repositórios conhecidos (e.g., Google Scholar, IEEE Explorer, ACM Digital Library):

SS-RQ1: ("POI recommendation" OR "point of interest" OR "recommender system") AND ("data type" OR "method" OR "problem")

SS-RQ2: ("POI recommendation" OR "point of interest" OR "recommender system") AND ("accuracy" OR "empirical" OR "experimental")

SS-RQ3: ("POI recommendation" OR "point of interest" OR "recommender system") AND ("accuracy" OR "diversity" OR "novelty" OR "experimental")

Propomos três critérios de inclusão e três de exclusão para filtrar estudos (i.e. livros, artigos, relatórios, etc.) relevantes capazes de responder às questões de pesquisa.

Critério de inclusão:

1. Estudos sobre recomendação de POI; E
2. Estudos publicados entre 2017 e 2019; E
3. Estudos que proponham novos modelos/métodos de recomendação de POI ou apresentem uma avaliação entre os já existentes.

Critério de exclusão:

1. Estudos que abordam métodos adotados em problemas de recomendação de POI, mas que focam em outros temas; OU
2. As versões antigas de um estudo já selecionado pelos critérios de inclusão; OU
3. As versões mais curtas de um estudo já selecionado pelos critérios de inclusão.

A seguir resumimos as principais conclusões deste trabalho, originalmente publicadas em [Werneck et al. 2020b, Werneck et al. 2021b]:

- De forma semelhante a outros domínios de recomendação, a maioria dos estudos selecionados avalia uma única dimensão de qualidade, acurácia, apesar do consenso na comunidade de sistemas de recomendação que outras dimensões de qualidade (e.g., novidade e diversidade) são importantes para avaliar a eficácia prática das recomendações.

- Em relação à configuração experimental adotada para avaliar as propostas, observamos uma baixa interseção de métricas e conjuntos de dados usados nos experimentos, juntamente com um grande número de métricas usadas em alguns estudos distintos. Além disso, faltam estudos comparativos entre as propostas existentes.
- Não encontramos nenhum estudo que aborde recomendação com diversificação considerando múltiplas dimensões de qualidade (e.g., categórica, geográfica), que é uma característica importante para o cenário real.

### 3. Diversificando Recomendações com Modelos Distintos e Não Ortogonais

Explorar POIs de diferentes categorias (e.g., restaurantes, museus, etc.) e as regiões distintas (local de trabalho, área de repouso, etc.), ao mesmo tempo é uma potencial maneira para melhorar a satisfação dos usuários. Em nosso trabalho propomos o **DisCovER**, originalmente publicado em [Werneck et al. 2021a], um método de diversificação que instancia o componente diversidade da Equação 1 como uma combinação linear ponderada dos métodos de diversificação geográfica e diversificação categórica propostos na literatura, como mostrado na Equação 2. Enquanto o  $\delta$  com valores próximos a 0 atribuem mais importância à influência geográfica, valores próximos de 1 atribuem mais importância à dimensão categórica.

$$S(i) = rel(i)^{1-\lambda} \cdot div_{gc}(i, R)^\lambda \quad (1)$$

$$div_{gc}(i, R) = (1 - \delta) \cdot div_{geo}(i, R) + \delta \cdot div_{cat}(i, R) \quad (2)$$

Trata-se de uma abordagem gulosa de dois passos para maximizar a diversificação *geográfica* e *categórica* simultaneamente. No primeiro, um SR base é executado para fornecer uma lista de recomendação ordenada  $R'$  de tamanho  $M \gg N$ . Na segunda etapa, o Algoritmo 1 é aplicado para selecionar iterativamente o POI  $P^* \in R'$  que maximiza a função objetivo a cada iteração. Destacamos que esta função foi originalmente proposta em [Han and Yamana 2017], utilizando uma combinação não-linear das dimensões de relevância e diversidade, assumindo que ambas as dimensões não são ortogonais. Enquanto a relevância  $rel(i)$  é medida pela pontuação atribuída pelo SR na primeira etapa, o *DisCovER* é usado para definir a diversidade  $div_{gc}(i, R)$ . A lista de recomendação final  $R$  contém os top- $N$  POIs com as maiores pontuações.

---

#### Algoritmo 1: DISCOVER ( $u, R', k$ )

---

```

1  $R \leftarrow \emptyset$ ;
2 foreach  $i \in range(0, k)$  do
3    $P^* \leftarrow argmax_{i \in R'} (rel(i)^{1-\lambda} \cdot div_{gc}(i, R)^\lambda)$ ;
4    $R \leftarrow R \cup \{P^*\}$ ;
5    $R' \leftarrow R' \setminus \{P^*\}$ ;
6 return  $R$ 

```

---

#### 3.1. Diversificação categórica

O *DisCovER* considera duas técnicas principais para modelar a diversificação categórica: (1) a cobertura categórica; e (2) a dissimilaridade categórica. Embora ambos estejam relacionados com a categoria de POI, assumimos que podem trazer informações complementares. Alguns POIs recomendados podem pertencer a várias categorias relevantes

(e.g., lanchonetes e churrascarias), mas vindo do mesmo nível hierárquico (e.g., restaurantes). A proposta combina estas duas técnicas em uma única métrica para alcançar a diversificação categórica, como mostrado na Equação 3. O primeiro termo refere-se à cobertura categórica, enquanto que o segundo termo refere-se à dissimilaridade categórica. É adotada uma aproximação da combinação linear ponderada. Enquanto  $div_{ild}$  mede a desordem da lista,  $div_{cov}$  está mais relacionado com a noção de relevância e é mais estável.

$$div_{cat}(i, R) = (1 - \phi) \cdot div_{cov}(R) + \phi \cdot div_{ild}(i, R) \quad (3)$$

A cobertura categórica deriva da métrica tradicional *Genre Coverage*, proposta em [Puthiya Parambath et al. 2016]. Ela representa a média das categorias relevantes  $R^+$  apresentadas na lista de recomendação do usuário  $R$ . Valores elevados de *Genre Coverage* indicam que os POIs recomendadas cobrem um grande número de **categorias relevantes**. Considera-se uma categoria como relevante para um usuário  $u$  se o usuário visitou POIs a partir desta categoria com mais frequência que o esperado para  $u$ , ao avaliar seu histórico de visitas.

$$div_{cov}(R) = \frac{\bigcup_{i \in R} genres(i) \cap \bigcup_{i \in R^+} genres(i)}{\bigcup_{i \in R^+} genres(i)} \quad (4)$$

Por sua vez, para medir a dissimilaridade categórica, o *DisCovER* considera o *Minimum List Distance* (LD) proposto em [Vargas and Castells 2011]. Basicamente, a dissimilaridade do POI  $i$  à lista de recomendação  $R$  é medida pelo menor valor de  $i$  para todos os POIs em  $R$ , como mostrado pela Equação 5. A dissimilaridade categórica é medida com base na distância entre as categorias dos POIs na distribuição hierárquica de categorias, tal como definido pela Equação 6 e originalmente proposto em [Castillo et al. 2008]. Os termos  $cat_i$  e  $cat_j$  representam as categorias dos POIs  $i$  e  $j$ , e  $sp(cat_i, cat_j)$  é a distância mais curta entre as categorias no distribuição hierárquica. Quando  $i$  ou  $j$  tiver mais de uma categoria, a métrica considera o menor valor de distância entre eles [Han and Yamana 2017].

$$div_{ild}(i, R) = LD(i, R) = \min_{j \in R} dissim_{cat}(i, j) \quad (5)$$

$$dissim_{cat}(i, j) = 1 - \frac{1}{(1 + sp(cat_i, cat_j))} \quad (6)$$

### 3.2. Diversificação geográfica

Diversificação geográfica adequada sobre POIs requer SsR para cobrir diferentes subáreas que cada usuário habitualmente visita. Mais especificamente, POIs recomendados: (1) devem ser posicionados em locais próximos dos visitados pelo usuário; e (2) recomendações sobre um local determinado  $l$  deve ser proporcional à frequência que cada usuário visita lugares em  $l$ . Ambos os requisitos são medidos por meio da métrica de diversificação geográfica proporcional  $PR_g$  [Han and Yamana 2017]. Basicamente,  $PR_g$  é o complemento da métrica de desproporcionalidade  $DP_g$ . Para se determinar o valor de cobertura  $c$  para cada POI considera-se todo o histórico de visitas dos usuários, a fim de não priorizar POIs localizados próximos a localização atual

dos usuários. Então, a diversidade geográfica é medida tal como proposto por *Han & Yamana* [Han and Yamana 2017] e definida na Equação 7.

$$div_{geo}(i, R) = \max(0, PR_g(\{i\} \cup R) - PR_g(R)) \quad (7)$$

#### 4. Diversificação Personalizada

Como mencionado anteriormente, usuários distintos têm diferentes predisposições e vontades de se locomover para satisfazer as suas necessidades. Embora muitos SsR de POI consideram contextos e preferências do usuário personalizadas, eles ainda ignoram o fato de que os usuários exibem um desejo distinto para a diversidade e novidade, afetando a relevância de cada dimensão da qualidade. Neste sentido, este trabalho, originalmente publicado em [Werneck et al. 2020a], foca nos níveis distintos de interesse dos usuários em diversificação categórica e/ou geográfica.

Em domínios de POI, a personalização pode influenciar mais do que normalmente na satisfação dos usuários, pois o esforço associado a cada revisão do usuário é maior que em outros cenários. Nesse cenário, o usuário normalmente avalia um POI só depois que ele se locomove para algum ponto da cidade, gastou algum dinheiro e tempo no lugar, e retorna para sua casa. Além disso, existem usuários com preferências ecléticas e há outros usuários que gostam apenas de visitar categorias específicas de POIs. Por esta razão, propomos personalizar o nosso método para aplicar diferentes níveis de diversificação categórica e geográfica para cada usuário. Basicamente, propomos personalizar o parâmetro  $\delta$  do *DisCovER*, responsável por equilibrar ambos os conceitos, alcançando mais (ou menos) diversificação. Definimos  $\delta$  na Equação 8 como a combinação de duas novas métricas propostas para aprender o nível de interesse dos usuários com base em suas preferências anteriores (o conjunto de treinamento).

$$\delta_u = \theta_{cat}(u) \cdot \theta_{geo}(u) \quad , \text{ onde:} \\ \theta_{cat}(u) = 1 - \frac{\min(C_u, C_P \cdot V_U)}{C_P \cdot V_U} \quad \text{e} \quad \theta_{geo}(u) = \min\left(\frac{D_u}{D_P}, 1\right) \quad (8)$$

Enquanto o  $\theta_{cat}$  representa o quão importante as categorias de POI são para usuários gostarem (ou não gostarem) da recomendação,  $\theta_{geo}$  representa quão disposto o usuário está a caminhar longas distâncias. Ambos estão estritamente relacionados com os conceitos de diversificação categórica e geográfica. Dado o conjunto  $P$  de POIs disponíveis e o conjunto  $U$  de usuários,  $\theta_{cat}$  mede a escassez de categorias consumidas de um usuário em relação a um usuário esperado. O valor esperado de categorias visitados por um usuário é a mediana das categorias distintas associadas com todos os POIs ( $C_P$ ) multiplicado pela mediana de visitas de todos os usuários ( $V_U$ ). Por outro lado,  $\theta_{geo}$  mede a distância caminhada pelo usuário ( $D_u$ ) em comparação com a média da distância existente entre todos os POIs na cidade ( $D_P$ ).  $D_u$  é a distância média entre os POIs visitados por um usuário  $u$  ao ponto centroide do distrito de atividade de  $u$ .  $D_P$  é a distância média de cada POI da cidade para o centro da cidade e representa o esforço médio que um usuário tem que fazer para visitar um lugar. A multiplicação de ambos os conceitos ( $\theta_{cat} \cdot \theta_{geo}$ ) fornece uma razão para nosso método priorizar os interesses de cada usuário.

## 5. Análise quantitativa

### 5.1. Configuração experimental

Para o processo de avaliação das propostas das seções 3 e 4, consideramos as cidades de Phoenix e Las Vegas nos EUA usando dados coletados entre 2004 e 2018 e publicamente disponibilizado pela *Yelp Dataset Challenge*. Semelhante à literatura, POIs visitados por menos de 5 usuários e usuários com menos de 20 registros de visita foram descartados. Como resultado, selecionamos 41.808 POIs e 701.152 registros de visita de 18.502 usuários para Phoenix, e 12.375 POIs e 220.329 registros de visita de 6.180 usuários para Las Vegas. Dividimos os dados em conjuntos de treino e teste com base no tempo associado com o histórico de cada usuário. Os primeiros 70% de registros de cada usuário são considerados treinamento, e os 30% restantes considerados para testes.

Para avaliar nossa proposta, realizamos uma extensa análise com nossa proposta em comparação com outras abordagens consolidadas da literatura. Aqui iremos apresentar uma fração de nossas análises, focando nos resultados principais de nosso trabalho, mais detalhes podem ser obtidos nos artigos publicados [Werneck et al. 2020a, Werneck et al. 2021a]. Um desses resultados envolve a avaliação do Multi-Attribute Utility (MAUT) de nosso método em comparação com os métodos linhas de base competitivos e analíticos. Nesse caso, o MAUT é utilizado para descrever a capacidade dos modelos satisfazerem múltiplas métricas simultaneamente. Para a utilização do MAUT, consideramos métricas de acurácia, novidade, e diversidade [Werneck et al. 2021a]: Precision; Recall; EPC; ILD; Genre Coverage; PRg.

### 5.2. Comparação multi-atributo com modelos estado da arte

Com o MAUT constatamos a superioridade de nossa proposta em relação aos outros métodos de reordenação em melhorar múltiplas dimensões de qualidade simultaneamente, evidenciado pelos altos valores de MAUT. Basicamente, os valores MAUT representam uma combinação ponderada de cada métrica analisada. Altos valores de MAUT indicam que o método é estável, pois pode melhorar a maioria das métricas analisadas simultaneamente. Como mostrado na Figura 1, o *DisCovER* alcança os maiores resultados de MAUT nas duas cidades, indicando que nossa abordagem pode alcançar ótimos resultados considerando todas as métricas. Apenas o *Geo-Div(PR)* consegue se aproximar dos resultados do *DisCovER* em Phoenix com 5 itens recomendados, uma vez que consegue grandes melhorias em  $PR_g$  [Werneck et al. 2021a]. No entanto, mesmo neste caso, o *Geo-Div(PR)* apresenta perdas significativas considerando Genre Coverage e ILD [Werneck et al. 2021a]. Os outros métodos de reordenamento não são tão eficazes considerando todas as métricas simultaneamente. Portanto, **os resultados do DisCovER em todos os conjuntos de dados, de fato, demonstram que estratégias que exploram simultaneamente a diversidade categórica e geográfica podem aumentar a diversificação, mantendo a precisão alta** [Werneck et al. 2021a].

### 5.3. Diversificação personalizada

Conforme apresentado anteriormente, basicamente, nossa proposta de personalização do *DisCovER* consiste em particularizar o parâmetro  $\delta$ . Nessa avaliação, calculamos o valor de  $\delta$  para cada usuário  $u$  em ambos os conjuntos de dados. Avaliamos a distribuição desses valores por meio função de distribuição acumulada (FDA), apresentada na Figura 2(c). Podemos notar que o  $\delta$  é sempre definido por valores menores do que 0.7.

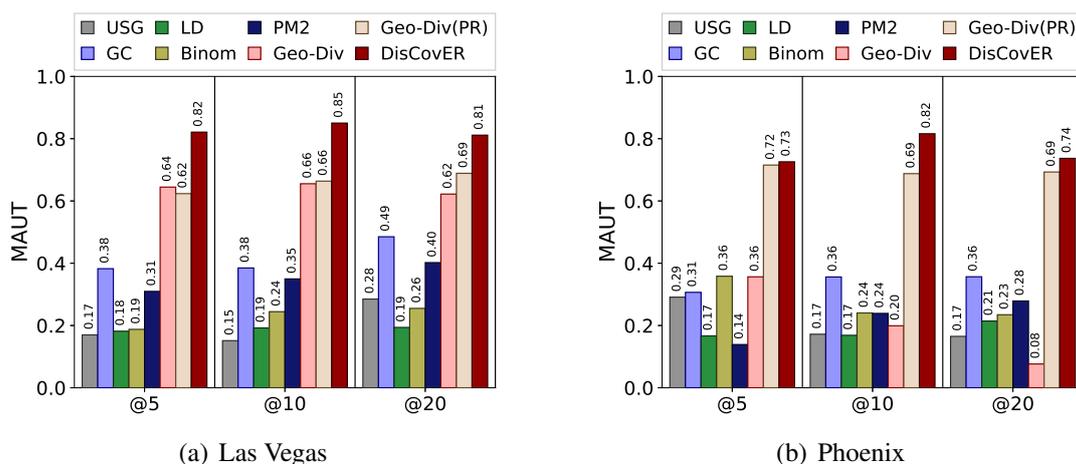


Figura 1. Análise de Multi-Attribute Utility (MAUT) de cada método de reordenação considerando todas as métricas simultaneamente.

A partir de distribuição dos valores de  $\delta$  em cada uma das coleções, podemos definir grupos de interesses para representar cada usuário. Basicamente, definimos o  $\theta_{cat}$  e o  $\theta_{geo}$  para cada usuário e criamos uma representação  $2D$  para eles, como mostrado na Figura 2(a) e 2(b). Então, definimos quatro grupos com base nos valores maiores (ou menores) do que 0.5 de  $\theta_{cat}$  e  $\theta_{geo}$ : **G1** é o grupo de *turistas animados*; **G2** é o grupo de *residentes animados*; **G3** é o grupo de *turistas preguiçosos*; e, **G4** é o grupo de *residentes preguiçosos*. Estas possíveis definições são feitas com base no nosso conhecimento sobre o domínio e a intuição por trás das métricas propostas para cada usuário.

- G1 (4929 usuários) • G3 (797 usuários) • G1 (9825 usuários) • G3 (7660 usuários)
- G2 (387 usuários) • G4 (162 usuários) • G2 (665 usuários) • G4 (523 usuários)

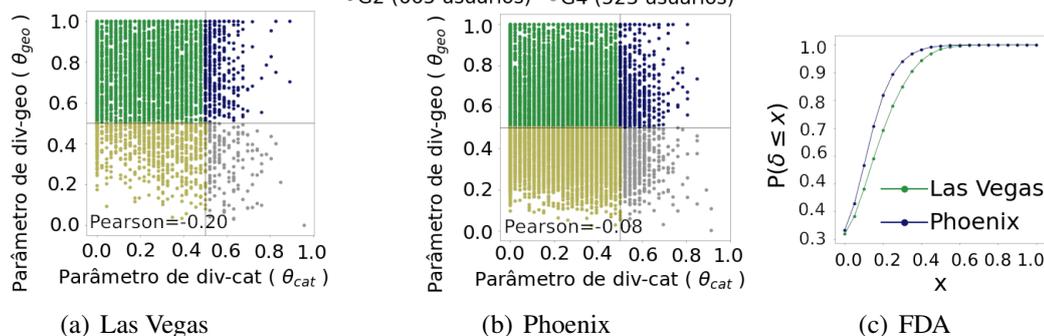
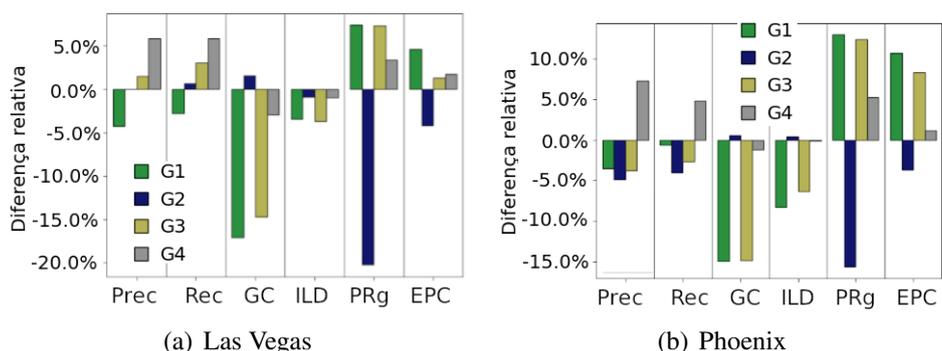


Figura 2. Representação dos usuários em Las Vegas e Phoenix, considerando as métricas propostas. Esta representação constrói os quatro grupos principais analisados. E FDA dos novos parâmetros definidos para  $\delta$  para cada usuário.

A partir dessas análises, foi aplicado o parâmetro personalizado  $\delta$  para cada usuário e analisados os resultados alcançados em ambas as cidades para os grupos definidos anteriormente. A Figura 3 mostra os ganhos relativos do nosso método personalizado em relação a versão original do DisCovER. **Podemos notar que nosso método é capaz de priorizar as dimensões de qualidade que melhor atendem as necessidades personalizadas de cada usuário, uma tarefa essencial em cenários reais [Werneck et al. 2020a].**

## 6. Framework de Sistemas de Recomendação de POIs

Por meio nosso mapeamento sistemático apresentado na seção 2, observamos que apesar da reconhecida importância da acurácia, há um consenso na comunidade sistemas de



**Figura 3. Ganhos relativos do DisCovER personalizado em relação ao não personalizado para os 10 primeiros itens**

recomendação de que outras dimensões da qualidade, como novidade e diversidade, também são essenciais para avaliar a eficácia prática das recomendações. Além disso, a maioria dos trabalhos não se preocupa em avaliar seus métodos em dimensões distintas. Essas observações apontam ao potencial dano quanto à reprodutibilidade e comparação direta dos resultados na área [Dacrema et al. 2021]. Nesse sentido, **este trabalho também apresenta um framework para uma avaliação uniforme e justa de métodos de recomendação de POI para suprir a falta de recursos de reprodutibilidade nesta linha de pesquisa.** Nosso framework, originalmente publicado em [Werneck et al. 2022], é composto por uma coleção de bibliotecas de software Python e uma imagem Docker para executar dois protocolos de recomendação POI:

- (1) *Reprodução da revisão de literatura:* É realizado por um pacote que expõe os dados e reproduz as visualizações do mapeamento sistemático [Werneck et al. 2021b].
- (2) *Reprodução de avaliações experimentais:* É composto por um pacote para apoiar a avaliação de novos métodos de recomendação de POI com baselines da literatura; usando conjuntos de dados distintos com muitos check-ins e avaliações de usuários; métricas de acurácia, novidade e diversidade; e aplicação de testes estatísticos.

## 7. Conclusão e Trabalhos Futuros

Neste trabalho apresentamos direcionamentos e problemas atuais na área de pesquisa de sistemas de recomendação de POIs por meio de uma revisão e mapeamento sistemático da literatura. Por meio desse mapeamento, identificamos algumas falhas ingênuas para lidar com o *trade-off* entre diversidade e precisão nas recomendações de pontos de interesse (POI). Nesse contexto, constatamos que alguns esforços de recomendações de POI estão, de alguma forma, desviando-se dos aprendizados básicos da área. Por esta razão, propomos o *DisCovER*, um método simples para explorar simultaneamente dimensões complementares. Além disso, neste trabalho também abordamos os distintos níveis de interesse dos usuários pela diversificação, avaliando a capacidade do *DisCovER* de personalizá-la conforme a preferência de cada usuário. Nosso método se mostrou apto a priorizar dimensões de qualidade que melhor atendam às necessidades personalizadas de cada usuário, tarefa essencial em cenários reais. Por fim, projetamos um framework completo e reprodutível dividido em dois pacotes: (1) um mapeador dos principais trabalhos publicados recentemente na literatura de recomendação de POI; (2) um benchmark com diferentes abordagens de recomendação com conjuntos de dados usuais e uma metodologia de avaliação de alto rigor científico. Como trabalho futuro, pretendemos analisar outras

abordagens para dividir os grupos de usuários e considerar a personalização de outros termos de nossa função objetivo, como a distinção de cobertura categórica e dissimilaridade.

## Referências

- Castillo, L., Armengol, E., Onaindía, E., Sebastián, L., González, J., Rodríguez, A., Fernández, S., Arias, J. D., and Borrajo, D. (2008). Samap: An user-oriented adaptive system for planning tourist visits. *Expert Systems with Applications*, 34(2):1318–1332.
- Dacrema, M. F., Boglio, S., Cremonesi, P., and Jannach, D. (2021). A troubling analysis of reproducibility and progress in recommender systems research. *ACM Transactions on Information Systems (TOIS)*, 39(2):1–49.
- Han, J. and Yamana, H. (2017). Geographical diversification in poi recommendation: toward improved coverage on interested areas. In *Proceedings of the Eleventh ACM Conference on Recommender Systems*, pages 224–228. ACM.
- Liu, B., Fu, Y., Yao, Z., and Xiong, H. (2013). Learning geographical preferences for point-of-interest recommendation. In *Proceedings of the 19th ACM SIGKDD international conference on Knowledge discovery and data mining*, pages 1043–1051. ACM.
- Lu, F. and Tintarev, N. (2018). A diversity adjusting strategy with personality for music recommendation. In *IntRS@ RecSys*, pages 7–14.
- Puthiya Parambath, S. A., Usunier, N., and Grandvalet, Y. (2016). A coverage-based approach to recommendation diversity on similarity graph. In *Proceedings of the 10th ACM Conference on Recommender Systems*, pages 15–22. ACM.
- Qian, T., Liu, B., Nguyen, Q. V. H., and Yin, H. (2019). Spatiotemporal representation learning for translation-based poi recommendation. *ACM Transactions on Information Systems (TOIS)*, 37(2):1–24.
- Vargas, S. and Castells, P. (2011). Rank and relevance in novelty and diversity metrics for recommender systems. In *Proceedings of the fifth ACM conference on Recommender systems*, pages 109–116. ACM.
- Werneck, H., Santos, R., Silva, N., Mourão, F., Pereira, A. C. M., and Rocha, L. (2021a). Effective and diverse poi recommendations through complementary diversification models. *Expert Systems with Applications*, 123:154–162.
- Werneck, H., Silva, N., Mourão, F., Pereira, A. C. M., and Rocha, L. (2020a). Combining complementary diversification models for personalized poi recommendations. In *Proceedings of the Brazilian Symposium on Multimedia and the Web*, page 209–212.
- Werneck, H., Silva, N., Pereira, A., Carvalho, M., Bellogín, A., Martínez-Gil, J., Mourão, F., and Rocha, L. (2022). A reproducible poi recommendation framework: Works mapping and benchmark evaluation. *Information Systems*, page 102019.
- Werneck, H., Silva, N., Viana, M., Pereira, A. C., Mourão, F., and Rocha, L. (2021b). Points of interest recommendations: Methods, evaluation, and future directions. *Information Systems*, 101:101789.
- Werneck, H., Silva, N., Viana, M. C., Mourão, F., Pereira, A. C., and Rocha, L. (2020b). A survey on point-of-interest recommendation in location-based social networks. In *Proceedings of the Brazilian Symposium on Multimedia and the Web*, pages 185–192.