

# Recomendação de Conteúdo Baseada em Localização e Interesse: uma aplicação com o CidadeSocial

Nícolás Terra Maia e Tiago Cruz de França

<sup>1</sup>Departamento de Computação – Universidade Federal Rural do Rio de Janeiro  
(UFRRJ) – Rio de Janeiro, RJ – Brazil

nicolasterramaia@gmail.com, tcruz.franca@gmail.com

**Abstract.** *Many applications seek to add value by exploiting the concept of geolocation, among them, CidadeSocial: a social media focused on the collaboration between people with similar interests that live in the same urban space. In CidadeSocial, information dissemination prioritizes people's interests, although they might not know each other, and must recommend content based on their proximity. This paper presents a recommender system that focuses on users' interest tags and physical proximity. An implementation was built as a service and software tests were run, then it was integrated into CidadeSocial.*

**Resumo.** *Muitas aplicações buscam agregar valor explorando o conceito de geolocalização, entre elas, o CidadeSocial: uma mídia social voltada à colaboração entre pessoas com interesses comuns que convivem nos mesmos espaços urbanos. No CidadeSocial, a disseminação da informação prioriza os interesses das pessoas, mesmo que estes não se conheçam, e precisa recomendar conteúdo com base na proximidade das pessoas. Este trabalho apresenta um sistema de recomendação que prioriza etiquetas de interesse e a proximidade física dos seus usuários. Uma implementação foi construída como um serviço, foram realizados testes de software e ela integrada ao CidadeSocial.*

## 1. Introdução

Diferentes empresas de diversos segmentos procuram oferecer recomendações de seus conteúdos de maneira cada vez mais precisa para conseguir a atenção dos usuários. Segundo Ricci *et al.* (2011), uma empresa pode usar sistemas de recomendação para: aumentar o número e variedade de itens vendidos, aumentar a fidelidade e engajamento do usuário, prender a atenção do usuário por mais tempo, etc.

A recuperação de conteúdo com base em recomendação é o foco deste trabalho que nasceu a partir da necessidade de um projeto chamado CidadeSocial [Tabak *et al.*, 2015; Correa *et al.*, 2018; Roger 2019; e França 2019]. O CidadeSocial é uma mídia social que dissemina o conteúdo das publicações de acordo com o interesse dos usuários, independente deles se seguirem ou fazerem parte de conexões previamente estabelecidas com outros usuários. Essa disseminação privilegia usuários que estão geograficamente próximos e que experimentam realidades semelhantes em seus contextos no momento em que usam o CidadeSocial.

O interesse da recomendação era conseguir apresentar aos usuários conteúdo do seu interesse (para que o considerem relevante), ranqueados de acordo com a proximidade entre quem recebe o conteúdo e o local onde foi publicada a mensagem,

considerando também a estampa de tempo para priorizar publicações mais recentes e com maior quantidade de interações (curtidas e comentários). Esses requisitos foram inicialmente observados por causa das demandas do CidadeSocial que possuía sua forma de recomendação ainda incompleta considerando todas essas características. O **problema** observado está expresso nesta pergunta: como recomendar conteúdo de acordo com (1) o interesse dos usuários e (2) sua proximidade com o local onde uma postagem foi realizada?

O **objetivo** foi desenvolver um serviço de recomendação que utilizasse os interesses dos usuários, sua localização, a localização das publicações e ordenasse o conteúdo dos mais recentes para os mais antigos.

Este artigo apresenta a **proposta** de criar um serviço de um Sistema de Recomendação chamado *CidadeSocial Recommender System (CSRS)*, o qual será baseado em interesses e coordenadas geográficas e que funcionará como um serviço.

Os testes apresentados foram realizados para essa mídia social. A localização do usuário no momento da busca e as etiquetas de interesses (previamente definidas) foram obtidos do CidadeSocial. Contudo, o CSRS foi implementado como um serviço que roda de forma independente do CidadeSocial e pode, potencialmente, atender a outras aplicações com as mesmas necessidades de recomendação de conteúdo. Diferente da implementação da recuperação de conteúdo do CidadeSocial, a implementação do CSRS levou em consideração escalabilidade e tratamento de grandes volumes de dados, embora esses aspectos não tenham sido observados nos testes apresentados neste trabalho.

Para avaliar a viabilidade técnica, a proposta foi implementada como um serviço web. Foram usado um mecanismo de indexação e recuperação de informação para as buscas por tópicos georreferenciados do CidadeSocial. As buscas são realizadas para atender as estratégias de recomendação. Com elas, os conteúdos de um conjunto de perfis foram definidos de forma personalizada.

## 2. Trabalhos Relacionados

Alguns trabalhos como [Yang et al., 2008; Saiph et al., 2012; Yin et al., 2013; Majid et al., 2013; Khalid et al., 2013] observaram e modelaram matematicamente diferentes algoritmos de “Recomendação de Conteúdo por Contexto”. Em [Wang et al., 2017], foi desenvolvido um algoritmo de recomendação por localização que leva em consideração comentários positivos ou negativos sobre determinado local e também o fato dos usuários poderem se interessar por tipos diferentes de lugares quando estão em cidades diferentes. Em [Capdevila et. al., 2016], foi desenvolvido um algoritmo de recomendação que considera avaliações e características de lugares. Eles coletaram dados do Foursquare para avaliar sua proposta. Embora essas propostas usem localização para fazer recomendações, a abordagem dos autores é diferente por não implementarem suas propostas como um serviço provisionado como uma API.

Em [Logesh et.al., 2018], foi desenvolvido um algoritmo de recomendação por localização em tempo real para mídias sociais com o objetivo de recomendar conteúdo específico para usuários de acordo com seu perfil e sua localização. Já em [Robles-Gómez et al., 2017] o sistema de recomendação foi desenvolvido utilizando as capacidades do motor de busca do Elasticsearch e o Kibana (<https://www.elastic.co>)

para visualização dos dados, porém não utiliza as capacidades de busca de conteúdo georreferenciado do Elasticsearch como feito nesta proposta.

Em [Hu et al., 2015] foi apresentada a relação da área de Recuperação de Informação com a área de Recomendação de Conteúdo de um ponto de vista teórico. A principal observação dos autores para este trabalho foi o desafio ao se utilizar um motor de busca desacoplado do sistema de recomendação. Esse desacoplamento foi observado na implementação desta proposta.

### 3. CidadeSocial

O CidadeSocial é um software de disseminação de informação através de dispositivos móveis que se beneficia da colaboração de seus usuários ao compartilhar informações rotuladas e georreferenciadas [França 2019]. A aplicação previa um sistema de recomendação, um modo de funcionamento *offline*, gamificação, um serviço de busca, um serviço de publicação de tópicos e comentários e a coleta de coordenadas geográficas de usuários através do GPS de seus dispositivos [Tabak et al., 2015; Roger 2019].

A comunicação entre usuários no CidadeSocial é feita através de tópicos e comentários nos tópicos. A disseminação desses tópicos e comentários é baseada em interesses e geolocalização. Ao usar o aplicativo, o usuário deveria ver, majoritariamente, tópicos relacionados aos seus interesses pessoais e que estejam associados a uma localização próxima da localização atual do usuário [Correa et al., 2018]. Embora tivesse uma definição, a formalização e implementação da recomendação no CidadeSocial não atendiam adequadamente ao que fora especificado.

### 4. CSRS: proposta e implementação

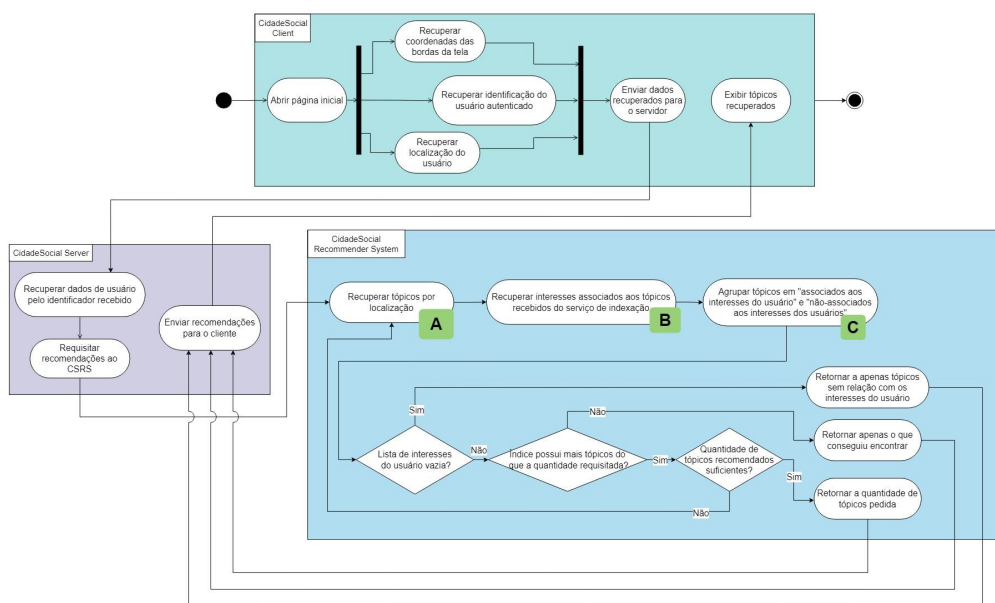
A proposta deste artigo observa um conjunto de características que devem ser representadas como funcionalidade do sistema de recomendação. Como características principais, o sistema de recomendação desejado deve:

- Funcionar como um serviço web *standalone* e fornecer uma API (*application programming interface*) de acesso;
- Definir e seguir uma paginação dada uma quantidade de mensagens por parâmetro;
- Recuperar uma porcentagem (80%, por exemplo) das mensagens de cada página prioritariamente com conteúdo relacionado ao interesse do usuário, ordenando o resultado por proximidade (mensagem publicada próxima a localização do usuário) e pelo dia e hora da publicação (mais recentes primeiro); e
- Completar as mensagens de uma página (por exemplo, 20% ou o que faltar para completar o total de mensagens) com conteúdo escolhido aleatoriamente e diferente dos interesses definidos para o usuário a fim de se possibilitar a identificação de novos conteúdos pelo acaso (*serendipity*).

Na Figura 1 há uma representação do fluxo de dados do CidadeSocial integrado ao CSRS. Primeiro, o usuário estará usando o cliente para dispositivos móveis do CidadeSocial e quando interagir com algum elemento que necessite de dados do servidor, serão enviadas uma ou mais requisições ao servidor principal do CidadeSocial, que por sua vez enviará requisições de recomendação para o CSRS.

No CSRS, o algoritmo segue como descrito no diagrama da Figura 1, com foco especial nas atividades A, B e C:

- Atividade A: É feita a recuperação dos tópicos por localização e no CSRS foi escolhido fazer isso através de uma ferramenta de indexação preparada para recuperação de itens geoespaciais. Por isso, uma etapa importante antes mesmo da recomendação acontecer é a indexação desses itens, ou seja, é preciso outra ferramenta que recupere os tópicos do banco de dados do CS e os envie para a ferramenta de indexação de fato. Uma vez indexados, esses dados podem ser recuperados na atividade A.
- Atividade B: São recuperados do banco de dados as etiquetas de interesses relacionados com os itens da atividade A. As etiquetas não foram indexadas por questões de estrutura da tabela do CidadeSocial e complexidade da criação de relacionamentos entre objetos na ferramenta de indexação escolhida, que é um armazenamento não-estruturado.
- Atividade C: Os itens já estão completos com suas etiquetas de interesse e são então agrupados entre itens "associados aos interesses do usuário" e itens "não-associados aos interesses dos usuários". É nessa etapa que o algoritmo consegue recomendar tópicos que o usuário tem interesses e também alguns outros poucos tópicos que ele não necessariamente se interessa.

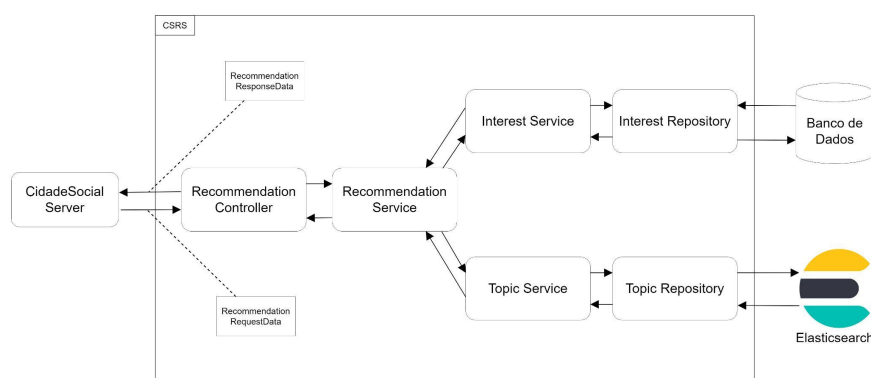


**Figura 1: Diagrama de Atividades do CS + CSRS**

O serviço do CSRS foi implementado em Java utilizando o *framework* Spring Boot (<https://spring.io/projects/spring-boot>) e irá se comunicar tanto com o servidor do CidadeSocial quanto com o mecanismo de recomendação implementado com Elasticsearch. O Elasticsearch possui apenas os dados de geolocalização das postagens e dados essenciais para identificá-los no banco de dados. O código desenvolvido está disponível em <https://github.com/ufrjr-labweb/csrs>.

A Figura 2 apresenta um diagrama com os detalhes da interação entre os diferentes componentes do sistema. O padrão MVC (model-view-controller) foi utilizado no sistema:

- As classes “*repository*” buscam seus artefatos (*interest* ou *topic*) nos respectivos locais de armazenamento (banco de dados ou *elasticsearch*).
- Ao receber seus respectivos artefatos, eles são passados para as classes “*service*” que irão realizar os processamentos individuais sobre esses artefatos.
- As classes *service* irão enviar o resultado do processamento individual para a classe “*RecommendationService*”, que combinará os resultados individuais para formar uma recomendação para cliente.
- A classe “*RecommendationController*” receberá a recomendação em sua forma final e a enviará de volta para o cliente que a requisitou.



**Figura 2: Interação das Classes do CSRS**

Para verificar o funcionamento da aplicação, foram feitos testes funcionais de API usando a ferramenta Postman (<https://www.postman.com>). Essa ferramenta permite que sejam especificadas, criadas e persistidas requisições HTTP para a API de um serviço web. Os testes do Postman foram executados a cada requisição enviada ao CSRS. Os testes e resultados foram estes:

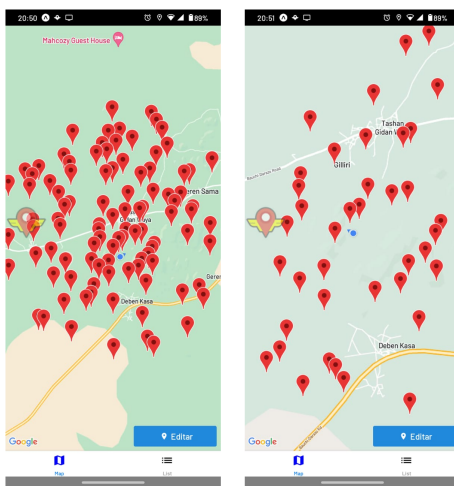
- A quantidade de tópicos recebidos foi a quantidade pedida? Sim, como a base era conhecida, os resultados retornados estavam de acordo com o que era esperado.
- Dos tópicos recebidos, a porção (definimos 80%) de tópicos relacionados aos interesses dos usuários foi alcançada? O resultado foi positivo para as situações nas quais os dados disponíveis atendiam a porcentagem esperada. Caso contrário, o máximo de mensagens foi devolvida e o sistema reajustado para completar com conteúdo mais recente disponível na base e usando apenas a localização (mais próximos possuem preferência).
- Os tópicos NÃO relacionados aos interesses dos usuários (20%) foram obtidos? Sim, sempre que existissem dados suficientes disponíveis para preencher a quantidade de mensagens desejadas.

Além do teste com o Postman, também foi desenvolvido um aplicativo para verificar se os tópicos recebidos realmente estavam nas coordenadas delimitadas pela tela do usuário. O aplicativo cliente foi desenvolvido para Android (Figura 3). Os testes foram realizados em um mapa. Para fins de testes, as requisições foram enviadas do aplicativo *mobile* diretamente para o CSRS ao invés de serem intermediadas pelo servidor do CidadeSocial. O objetivo nesse caso foi observar que todos os tópicos retornados pelo serviço de recomendação realmente estavam dentro das coordenadas mostradas na tela e estavam próximos de uma coordenada central (representando o

"usuário fictício"). Esses testes também foram bem-sucedidos, sempre retornando itens dentro do quadrilátero esperado.

## 5. Considerações Finais

Este artigo apresentou um sistema de recomendação para o CidadeSocial: o CSRS (CidadeSocial *Recommender System*), que é uma proposta para recomendação de conteúdo baseada na localização instantânea do usuário e em seus interesses. Além dos dados de interesse, também são adicionadas outras publicações para explorar a identificação de outros interesses do usuário. Foi feita uma implementação como um serviço independente, mas inspirado e alinhado com as especificações do CidadeSocial. Foram realizados testes para identificação do funcionamento da implementação e verificação da viabilidade da proposta. Os resultados observados foram considerados indicativos positivos da viabilidade técnica e adequação da implementação como serviço de recomendação baseado em localização e interesse.



**Figura 3: Visualização de tópicos em aplicativo para teste**

Como limitação, não foram realizados estudos do ponto de vista da escalabilidade e com grandes volumes de dados, tendo em vista que no primeiro momento o objetivo foi verificar a recomendação. Para o futuro, ainda é necessário testar a performance da implementação com um volume maior de dados, definir perfis de usuários e o conteúdo esperado como retorno por parte do sistema de recomendação, realizar testes com usuários reais e expandir a discussão sobre complexidade, tempo de resposta e possíveis otimizações do código.

## Referências

- Correa, A. C.; Roger, E.; Gomes, J. O.; Oliveira, J.; França, T., 2018. CidadeSocial: An Application Software for Opportunistic and Collaborative Engagement of Urban Populations. COMMUNICATIONS IN COMPUTER AND INFORMATION SCIENCE (PRINT), v. 926, p. 141-155, 2018.
- França, Tiago Cruz de, 2023. "ANDARE: um framework para inclusão da análise de dados de mídias sociais no contexto da preparação e resposta à emergência em

- situações de manifestações de massa", 2019, Tese (Doutorado) PPGI-UFRJ, Rio de Janeiro, 2019, <https://tinyurl.com/tmaydae4>. Acessado em 08 de Mar. de 2023.
- Khalid, Osman, et al., 2013. OmniSuggest: A ubiquitous cloud-based context-aware recommendation system for mobile social networks. *IEEE Transactions on Services Computing*, 2013, vol. 7, no 3, p. 401-414.
- Majid et al., 2013. A context-aware personalized travel recommendation system based on geotagged social media data mining. *International Journal of Geographical Information Science*, 2013, vol. 27, no 4, p. 662-684.
- Ricci, F.; Rokach, L.; Shapira, B., 2011. Introduction to recommender systems handbook. In: *Recommender systems handbook*. Springer, Boston, MA, 2011. p. 1-35.
- Robles-Gómez, A. et al., 2017. Using Kibana and Elasticsearch for the Recommendation of Job Offers to Students. En *LASI-SPAIN*. 2017. p. 93-99.
- Roger, E., 2019. CidadeSocial: um aplicativo para comunicação oportunística em ambientes urbanos. 2019. Trabalho de Conclusão de Curso. (Graduação em Sistemas de Informação) - Universidade Federal Rural do Rio de Janeiro. Orientador: Tiago Cruz de França.
- Saiph Savage et al., 2012. I'm feeling loco: A location based context aware recommendation system. En *Advances in Location-Based Services*. Springer, Berlin, Heidelberg, 2012. p. 37-54.
- Tabak, P.; Figueiredo, E.; França, T. C.; Oliveira, J., 2015 . Campus Social: uma ferramenta para trocas oportunísticas de informações em campi universitários. In: 42 Seminário Integrado de Software e Hardware (SEMISH), 2015, Recife. XXXV Congresso da Sociedade Brasileira de Computação, 2015. v. 1.
- Yang, Wan-Shiou; Cheng, Hung-Chi; Dia, Jia-Ben, 2008. A location-aware recommender system for mobile shopping environments. *Expert Systems with Applications*, v. 34, n. 1, p. 437-445, 2008.
- Yin, Hongzhi et al., 2013. Lcars: a location-content-aware recommender system. In: *Proceedings of the 19th ACM SIGKDD international conference on Knowledge discovery and data mining*. 2013. p. 221-229.
- Hu, Si ying Diana; Delgado, Joaquin, 2015. Scalable recommender systems: where machine learning meets search. In: *Proceedings of the 9th ACM Conference on Recommender Systems*. 2015. p. 365-366.
- Logesh, R.; Subramaniaswamy, V.; Vijayakumar, V., 2018. A personalized travel recommender system utilizing social network profile and accurate GPS data. *Electronic Government, an International Journal*, v. 14, n. 1, p. 90-113, 2018.
- Capdevila, Joan; Arias, Marta; Arratia, Argimiro, 2016. GeoSRS: A hybrid social recommender system for geolocated data. *Information Systems*, v. 57, p. 111-128, 2016.
- Wang, Hao et al., 2017. A location-sentiment-aware recommender system for both home-town and out-of-town users. In: *Proceedings of the 23rd ACM SIGKDD international conference on knowledge discovery and data mining*. 2017. p. 1135-1143.