

NaVISOL: Um Chatbot com Sistema de Recomendação para o Mapa Digital da Cidade de Sobral

Alex de Sousa Ramos¹, Evecleison Albuquerque do Nascimento¹,
João Paulo de Abreu Militão¹, Iális Cavalcante de Paula Júnior¹

¹ Programa de Pós-Graduação em Engenharia Elétrica e de Computação
Universidade Federal do Ceará (UFC) – Sobral – CE – Brasil

alexssr@alu.ufc.br, evecleisonce@gmail.com, jaopaulomilitao@gmail.com,

ialis@sobral.ufc.br

Abstract. *Geographic Information System (GIS) platforms provide large volumes of territorial data, but their exploration still presents usability challenges for non-specialized users. This paper presents NaVISOL, a chatbot integrated into the Sobral em Mapas platform that combines natural language processing and a recommender system to support the proactive discovery of geospatial information. The system uses the Rasa framework to interpret natural language queries and a recommendation model based on collaborative filtering and Singular Value Decomposition (SVD) of implicit feedback. Results indicate that the approach was able to identify latent navigation patterns among map layers and assist users in discovering relevant urban open data.*

Resumo. *Plataformas baseadas em Sistemas de Informação Geográfica (GIS) disponibilizam grande volume de dados territoriais, porém sua exploração ainda apresenta desafios de usabilidade para usuários não especializados. Este trabalho apresenta o NaVISOL, um chatbot integrado à plataforma Sobral em Mapas que combina processamento de linguagem natural e um sistema de recomendação para apoiar a descoberta proativa de informações geográficas. O sistema utiliza o framework Rasa para interpretar consultas em linguagem natural e um modelo de recomendação baseado em filtragem colaborativa e decomposição em valores singulares (SVD) sobre feedback implícito. Os resultados indicam que a abordagem foi capaz de identificar padrões latentes de navegação entre camadas do mapa e contribuir para a democratização do acesso a dados abertos urbanos.*

1. Introdução

O avanço das Tecnologias da Informação e Comunicação (TIC) tem impulsionado a transformação digital das cidades, contribuindo para o surgimento do conceito de *Smart Cities*. Esse paradigma busca integrar tecnologia, dados e gestão urbana com o objetivo de melhorar a qualidade de vida da população e tornar os serviços públicos mais eficientes. A utilização de plataformas digitais, sensores e sistemas de análise de dados permite que gestores públicos tomem decisões mais assertivas e que os cidadãos tenham maior acesso a informações e serviços. Nesse contexto, a tecnologia torna-se um elemento essencial para promover cidades mais inteligentes, sustentáveis e centradas no cidadão [Kaiser 2024].

Entre as tecnologias que apoiam esse processo, destacam-se os Sistemas de Informação Geográfica (GIS), responsáveis por armazenar, processar e visualizar dados geoespaciais relacionados ao território. Esses sistemas permitem integrar informações sobre infraestrutura urbana, transporte, equipamentos públicos e indicadores ambientais em uma única plataforma. Por meio da visualização cartográfica e da análise espacial, os GIS auxiliam no planejamento urbano, na gestão de recursos e na transparência das informações públicas, tornando-se ferramentas fundamentais para a administração municipal e para o acesso da população a dados territoriais [Zhao et al. 2025].

Apesar de seu grande potencial, muitas plataformas GIS ainda apresentam desafios relacionados à usabilidade e acessibilidade. Interfaces tradicionais costumam exigir conhecimentos técnicos específicos, como a manipulação de camadas cartográficas, filtros e ferramentas de análise espacial. Para usuários não especializados, essa complexidade pode dificultar a navegação e a compreensão das informações disponíveis, gerando sobrecarga cognitiva e limitando o aproveitamento dos dados geográficos disponibilizados pelas plataformas [Atzmanstorfer et al. 2025].

Uma alternativa para reduzir essas barreiras é o uso de agentes conversacionais baseados em inteligência artificial, que permitem a interação com sistemas computacionais por meio de linguagem natural. Chatbots possibilitam que os usuários realizem consultas simplesmente formulando perguntas, sem a necessidade de navegar por menus ou interfaces complexas, sendo amplamente utilizados para facilitar o acesso a informações em diferentes domínios digitais [Sanjaya et al. 2023]. Entretanto, muitas dessas soluções ainda dependem que o usuário possua algum conhecimento prévio sobre os dados disponíveis no sistema. Em plataformas GIS, por exemplo, o usuário frequentemente precisa conhecer o nome de uma camada, categoria ou elemento geográfico específico para formular sua consulta de forma adequada. Esse requisito pode limitar o uso dessas ferramentas por usuários menos experientes e dificultar a descoberta de informações relevantes em ambientes com grande volume de dados geográficos. Nesse contexto, sistemas de recomendação surgem como uma abordagem promissora para apoiar a exploração desses dados, permitindo sugerir conteúdos relevantes com base em padrões de uso, contexto da interação ou similaridade entre informações geográficas [Acharya et al. 2023].

Para mitigar esse problema e ampliar a capacidade de exploração do sistema, este trabalho propõe o desenvolvimento do NaVISOL (Navegador Virtual Inteligente de Sobral), um chatbot integrado à plataforma Sobral em Mapas que combina técnicas de processamento de linguagem natural com um sistema de recomendação. A proposta busca não apenas responder consultas realizadas pelos usuários, mas também sugerir camadas geográficas relevantes com base no contexto da interação e nos padrões de uso observados na plataforma, promovendo uma experiência de navegação mais intuitiva e orientada à descoberta de informações.

Este artigo está estruturado da seguinte forma: a Seção 2 apresenta e discute os trabalhos relacionados; a Seção 3 descreve a metodologia adotada no desenvolvimento da proposta; a Seção 4 apresenta e analisa os resultados obtidos; e, por fim, a Seção 5 reúne as conclusões do trabalho e apresenta perspectivas para pesquisas futuras.

2. Trabalhos Relacionados

As inovações tecnológicas têm desempenhado um papel relevante na transformação digital de diferentes setores da sociedade, impulsionando melhorias em eficiência, produtividade e acesso à informação [Domnich 2022]. Nesse contexto, os agentes conversacionais têm se destacado como uma das aplicações mais promissoras da inteligência artificial, sendo utilizados para automatizar interações e melhorar a prestação de serviços em diversos domínios, como comércio eletrônico, educação, turismo e serviços financeiros ([Sanjaya et al. 2023]. No setor público, a adoção dessas tecnologias tem sido motivada pela necessidade de ampliar a eficiência administrativa e aproximar os cidadãos das infraestruturas digitais de governo, tornando serviços públicos mais acessíveis e transparentes [Ribeiro and Segatto 2025].

Apesar desse avanço, a literatura evidencia que grande parte das aplicações de inteligência artificial no setor público ainda se baseia em sistemas predominantemente reativos. Esses sistemas são projetados principalmente para responder solicitações específicas dos usuários, executando tarefas como responder perguntas frequentes ou orientar o preenchimento de formulários administrativos [Bochanov 2024]. Embora essa abordagem contribua para a automação de processos, ela limita a interação a um fluxo linear de pergunta e resposta, reduzindo o potencial desses sistemas para apoiar processos mais complexos de descoberta e exploração de informações [Misuraca and Noordt 2020].

Em contraste com esse paradigma reativo, estudos recentes têm enfatizado o potencial de sistemas proativos, capazes de antecipar necessidades dos usuários e sugerir conteúdos relevantes com base em padrões de comportamento e contexto de interação [Wirtz et al. 2019]. Entretanto, a maior parte dessas aplicações preditivas tem sido direcionada para processos internos da administração pública, como análise de políticas públicas ou apoio à gestão administrativa, e não diretamente para a experiência de interação do cidadão com sistemas digitais [OECD 2025]. Esse cenário evidencia uma lacuna importante entre o potencial da inteligência artificial para oferecer interações mais inteligentes e sua aplicação efetiva em interfaces voltadas ao usuário final.

No campo da inteligência artificial aplicada a dados geoespaciais, conhecido como Geospatial Artificial Intelligence (GeoAI), desafios semelhantes também são observados. Pesquisas recentes indicam que modelos de linguagem de grande escala ainda enfrentam limitações significativas na interpretação de relações espaciais, como distância, topologia e localização relativa, devido à natureza ambígua da linguagem natural em contraste com a estrutura formal dos dados geográficos [Mansourian and Oucheikh 2024]. Como consequência, muitos sistemas conversacionais aplicados a plataformas geoespaciais continuam baseados em paradigmas de “comando e controle”, nos quais o usuário precisa formular comandos específicos e estruturados para acessar informações. Mesmo quando integrados a modelos de linguagem avançados, esses sistemas ainda apresentam limitações na exploração e descoberta espontânea de dados geográficos [Ji et al. 2025].

Paralelamente, o desenvolvimento de sistemas de recomendação tem sido amplamente explorado como estratégia para apoiar usuários na descoberta de informações em ambientes digitais com grande volume de dados. No entanto, no domínio geoespacial, a maior parte das pesquisas concentra-se na recomendação de pontos de interesse (Points of Interest – POIs), como restaurantes, hotéis ou atrações turísticas. Estudos como [Liu et al. 2025] reforçam essa tendência ao demonstrar que muitos sistemas de

recomendação espacial são direcionados a locais de consumo ou visitação. Embora essas abordagens tenham demonstrado bons resultados em aplicações relacionadas ao turismo ou mobilidade urbana, elas exploram apenas parcialmente o potencial de recomendação em ambientes geoespaciais mais complexos.

Em plataformas baseadas em Sistemas de Informação Geográfica (GIS), os dados são frequentemente organizados em camadas temáticas, que representam fenômenos espaciais como densidade populacional, zoneamento urbano, redes de transporte ou distribuição de serviços públicos. Recomendar esse tipo de informação apresenta desafios adicionais quando comparado à recomendação de POIs, pois envolve a identificação de relações semânticas e espaciais mais complexas entre diferentes conjuntos de dados. Trabalhos como [Luo et al. 2020] demonstram que mesmo a recomendação de objetos espaciais em diferentes níveis de granularidade exige modelos capazes de capturar relações latentes e hierarquias espaciais, indicando a complexidade adicional envolvida na recomendação de camadas geográficas completas.

Outro fator relevante nesse contexto é o papel do engajamento do usuário em ambientes digitais. Estudos sobre interação humano-computador indicam que experiências sustentáveis de uso dependem da presença de mecanismos que estimulem a motivação intrínseca dos usuários, ou seja, o interesse genuíno em explorar e descobrir novas informações [Looyestyn et al. 2017]. Embora abordagens baseadas em gamificação tenham sido amplamente exploradas para estimular a motivação extrínseca [Interaction Design Foundation 2016], sistemas de recomendação têm sido apontados como mecanismos capazes de promover experiências de descoberta mais naturais e contínuas. Nesse sentido, tais sistemas podem atuar como catalisadores de serendipidade, permitindo que os usuários descubram conteúdos relevantes que inicialmente não estavam procurando explicitamente [Kotkov et al. 2017].

Para viabilizar esse tipo de recomendação em ambientes geoespaciais, diversos estudos têm explorado o uso de feedback implícito como fonte de informação sobre preferências dos usuários. Em sistemas de mapas digitais, comportamentos como ações de zoom, movimentação da visualização (pan) e ativação de camadas podem fornecer sinais relevantes sobre o interesse do usuário em determinados tipos de informação geográfica [Unrau and Kray 2021]. Entretanto, a utilização desses dados apresenta desafios adicionais relacionados à esparsidade de interações, à complexidade dos dados espaciais e à necessidade de modelar relações contextuais entre diferentes elementos geográficos.

O presente trabalho diferencia-se das abordagens existentes ao propor a integração de um agente conversacional com um sistema de recomendação voltado à sugestão de camadas geoespaciais em plataformas GIS públicas. Enquanto grande parte das soluções concentra-se na recomendação de itens individuais e em interações predominantemente reativas, a proposta busca incorporar elementos de proatividade baseados no contexto de interação dos usuários. Além disso, o uso de feedback implícito aliado a técnicas de filtragem colaborativa permite lidar com a esparsidade dos dados e explorar relações complexas entre camadas geográficas, contribuindo para apoiar a descoberta de informações em ambientes com grande volume de dados.

No cenário nacional da Computação Urbana, a disponibilização de dados abertos (*Open Data*) e as iniciativas de *Data for Good* são passos fundamentais para a trans-

parência pública. Contudo, a apropriação desses recursos pela população esbarra em barreiras de acessibilidade e usabilidade [Santos 2022]. Este trabalho busca resolver esse problema ao propor a integração de um agente conversacional com um sistema de recomendação focado na sugestão proativa de camadas geoespaciais. O uso de feedback implícito, em conjunto com a filtragem colaborativa, ajuda a contornar a esparsidade dos dados e diminui a sobrecarga cognitiva do cidadão. Isso resulta em uma exploração mais fluida e acessível em plataformas com grande volume de informações urbanas.

3. Metodologia

Este trabalho foi desenvolvido em colaboração entre a Universidade Federal do Ceará (UFC) e a Prefeitura Municipal de Sobral, no contexto de dois projetos conduzidos de forma integrada pela mesma equipe de pesquisa: a plataforma *Sobral em Mapas*¹ e o chatbot NaVISOL. Essas iniciativas têm como objetivo apoiar usuários na exploração de dados geográficos da cidade. O sistema utiliza tecnologia de Sistemas de Informação Geográfica (GIS) e dados geográficos abertos para exibir construções, rotas e diferentes convenções cartográficas, como linhas de transporte público, ciclovias, pontos de interesse e divisões administrativas.

Para facilitar a navegação nesse ambiente informacional, foi desenvolvido um agente conversacional integrado ao sistema, capaz de interpretar consultas em linguagem natural e auxiliar os usuários na exploração dos dados geográficos. Além de responder perguntas e fornecer orientações, o sistema incorpora um mecanismo de recomendação capaz de sugerir camadas geográficas relevantes com base no comportamento coletivo de navegação e no contexto da interação.

A metodologia adotada neste trabalho envolve quatro etapas principais: (i) levantamento de requisitos e análise das demandas dos usuários; (ii) desenvolvimento do agente conversacional; (iii) implementação do sistema de recomendação híbrido; e (iv) avaliação do sistema e da experiência do usuário.

3.1. Análise das Demandas dos Usuários

A identificação das demandas dos usuários foi conduzida em colaboração com as equipes da Secretaria do Planejamento e Gestão (SEPLAG) e da Secretaria do Urbanismo e Meio Ambiente (SEUMA). Inicialmente foram realizadas reuniões técnicas para identificar as principais necessidades informacionais relacionadas à consulta de dados urbanos, com foco em rotas de transporte público, edificações, infraestrutura urbana e pontos de interesse da cidade. A partir desse levantamento, foram definidos os principais cenários de uso e perfis de usuários da plataforma.

Durante o processo de desenvolvimento foram realizados testes com usuários reais, permitindo validar os fluxos de interação do chatbot e identificar oportunidades de melhoria. O processo seguiu uma abordagem iterativa composta pelas etapas de levantamento de requisitos, implementação inicial, testes com usuários, coleta de feedback e refinamento progressivo do sistema, como ilustrado na Figura 1.

Para a coleta de dados da avaliação do sistema, foi aplicado um formulário com moradores da cidade de Sobral. Devido à ausência de dados históricos sobre o volume

¹A plataforma encontra-se provisoriamente disponível em: <https://spacesolutions.alphi.media/sobralmapas/public/>

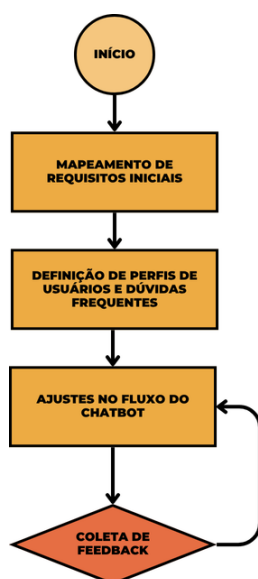


Figura 1. Fluxo iterativo de desenvolvimento do chatbot.

exato de usuários ativos na plataforma, utilizou-se o método de cálculo amostral para população infinita. Adotou-se um nível de confiança de 95%, um erro amostral de 5% e uma proporção estimada de 13%. Esse valor de 13% foi escolhido como uma estimativa realista e conservadora do engajamento da população local com ferramentas digitais da gestão municipal, resultando em uma amostra mínima recomendada de 174 participantes.

Os dados coletados por meio desse instrumento foram utilizados tanto para a avaliação do sistema quanto como insumo para o processo de treinamento e refinamento do chatbot e do sistema de recomendação, conforme o ciclo iterativo apresentado na Figura 1. Esse processo permitiu ajustar continuamente o modelo com base nas interações reais dos usuários, contribuindo para a melhoria da qualidade das respostas e da relevância das recomendações fornecidas pela plataforma.

3.2. Arquitetura do Sistema

O agente conversacional foi desenvolvido utilizando o framework Rasa, uma plataforma de código aberto amplamente utilizada para aplicações de Processamento de Linguagem Natural (PLN). A arquitetura do sistema, ilustrada na Figura 2, é composta por três componentes principais: a interface web da plataforma Sobral em Mapas, o servidor do chatbot e o módulo de recomendação. A comunicação entre esses componentes ocorre por meio de requisições HTTP utilizando a API REST do Rasa, permitindo a troca de mensagens entre a interface do usuário e o servidor responsável pelo processamento das interações.

Quando o usuário envia uma mensagem pela interface do chat, essa informação é encaminhada ao servidor do chatbot, onde o módulo Rasa NLU realiza a análise do texto com o objetivo de identificar a intenção da mensagem e extrair entidades relevantes, como nomes de ruas, bairros ou pontos de interesse. Em seguida, o Rasa Core processa essas informações e, com base nas políticas de decisão e no histórico de diálogo, determina a ação mais adequada a ser executada.

As ações são implementadas no módulo *actions* do Rasa, responsável por executar

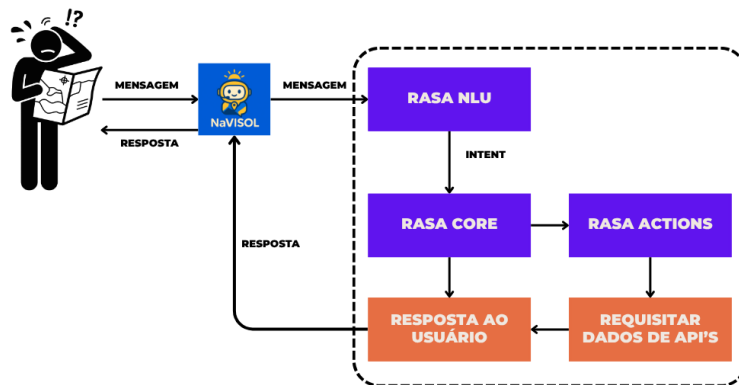


Figura 2. Arquitetura do sistema NaVISOL e fluxo de interação entre seus componentes.

operações específicas do sistema, incluindo consultas à base de dados e a integração com o módulo de recomendação. Esse módulo utiliza informações de contexto e histórico de interação para sugerir camadas geoespaciais relevantes ao usuário. As respostas geradas podem consistir tanto em mensagens textuais quanto em comandos que manipulam a visualização do mapa, como ativação de camadas ou marcação de elementos geográficos.

3.3. Pipeline de Processamento de Linguagem Natural

O pipeline de processamento de linguagem natural adotado neste trabalho combina técnicas de pré-processamento textual com modelos baseados em aprendizado profundo. O fluxo inicia-se com a segmentação da mensagem do usuário e a extração de características linguísticas, seguida da geração de representações vetoriais utilizadas pelo modelo de classificação.

O pipeline inclui os seguintes componentes:

- **WhitespaceTokenizer**: responsável pela segmentação do texto em tokens;
- **RegexFeaturizer** e **LexicalSyntacticFeaturizer**: utilizados para extrair padrões linguísticos e características sintáticas;
- **CountVectorsFeaturizer**: responsável pela vetorização baseada em *bag-of-words* e n-gramas;
- **DIETClassifier**: modelo multitarefa responsável pela classificação de intenções e extração de entidades;
- **FallbackClassifier**: utilizado para tratar situações de baixa confiança na classificação.

Além da configuração do pipeline, foram definidos e refinados iterativamente os arquivos de configuração do Rasa, incluindo intenções (*intents*), exemplos de treinamento, regras e *stories*, que descrevem os fluxos de diálogo do agente conversacional². Esses componentes foram ajustados ao longo do desenvolvimento com base em testes sucessivos e no feedback obtido durante as interações com usuários, permitindo melhorar progressivamente a capacidade do sistema de interpretar as perguntas e fornecer respostas adequadas ao contexto da plataforma Sobral em Mapas.

²Os arquivos de configuração e treinamento do chatbot estão disponíveis em: <https://github.com/ASRSQ/NaVISOL>

3.4. Sistema de Recomendação

O sistema de recomendação adotado combina duas abordagens complementares: recomendação baseada no contexto da interação conversacional e filtragem colaborativa item-a-item baseada em similaridade entre mapas. A recomendação colaborativa utiliza *feedback implícito* obtido a partir do comportamento de navegação dos usuários. Diferentemente de avaliações explícitas, esse tipo de *feedback* pode ser inferido a partir de diferentes sinais de interação, como cliques, histórico de navegação ou tempo de permanência em determinados conteúdos. Neste trabalho, optou-se por utilizar o tempo de permanência do usuário em cada camada do mapa como indicador de interesse. Essa escolha fundamenta-se na natureza das interações em sistemas geoespaciais, nos quais a exploração das camadas ocorre de forma contínua e não estruturada, envolvendo navegação, inspeção visual e sobreposição de informações.

Para cada interação foi calculado um *score* parcial, definido como a proporção do tempo de visualização de uma camada em relação ao tempo total da sessão:

$$score_{parcial} = \frac{tempo_i}{tempo_{total_i}} \quad (1)$$

As interações foram agrupadas por par usuário–mapa, e o *score* médio foi calculado conforme a Equação 2, onde (n) representa o número de interações do usuário (u) com o mapa (m).

$$score_{u,m} = \frac{1}{n} \sum_{i=1}^n score_{parcial_i} \quad (2)$$

A partir desses valores foi construída uma matriz de interação $R \in R^{m \times n}$, na qual m representa o número de mapas e n o número de usuários. Para identificar relações latentes entre os mapas foi aplicada a Decomposição em Valores Singulares (SVD):

$$R = U\Sigma V^T \quad (3)$$

A utilização da decomposição em valores singulares justifica-se pela sua capacidade de reduzir a dimensionalidade da matriz de interações e capturar padrões latentes de similaridade entre os mapas, mesmo na presença de dados altamente esparsos. Essa característica é particularmente relevante neste contexto, uma vez que as interações dos usuários com as camadas geoespaciais são limitadas e distribuídas de forma desigual, dificultando a aplicação de métodos baseados apenas em coocorrência direta.

Em seguida, a decomposição foi truncada preservando apenas as (k) maiores componentes singulares. A representação latente dos mapas foi obtida por meio da projeção:

$$X_{mapas} = U_k \Sigma_k \quad (4)$$

A similaridade entre dois mapas (i) e (j) foi calculada utilizando a similaridade de cosseno, conforme a Equação 5:

$$sim(i, j) = \frac{x_i \cdot x_j}{|x_i||x_j|} \quad (5)$$

onde x_i e x_j representam os vetores latentes associados aos mapas. A partir desses valores é construída uma matriz de similaridade $S \in R^{m \times m}$, na qual cada elemento $s_{i,j}$ representa o grau de similaridade entre os mapas i e j . Essa matriz possui dimensão mapa \times mapa e armazena as relações de afinidade entre todas as camadas geográficas disponíveis no sistema.

As recomendações são geradas consultando essa matriz de similaridade. Dado um mapa atualmente acessado pelo usuário, o sistema identifica os mapas com maior valor de similaridade em relação a ele e os sugere como recomendações. Dessa forma, as sugestões refletem padrões de navegação observados nas interações coletivas dos usuários e relações latentes entre as camadas geográficas, contribuindo para apoiar a descoberta de informações em ambientes com grande volume de dados.

3.5. Avaliação do Sistema

A avaliação do sistema foi realizada em duas dimensões principais: experiência do usuário e desempenho do sistema de recomendação.

A experiência do usuário foi avaliada por meio de um questionário estruturado aplicado aos participantes do estudo.³ O instrumento, intitulado “*Avaliação de chatbot Sobral em Mapas*”, foi desenvolvido com o objetivo de analisar a interação dos usuários com o chatbot da plataforma. O formulário foi estruturado em três partes: (i) caracterização do perfil do usuário, incluindo uso de aplicativos de mensagens e familiaridade com chatbots; (ii) avaliação da interação com o sistema por meio de uma escala Likert de 1 a 5, contemplando aspectos como facilidade de uso, compreensão das respostas e relevância das recomendações; e (iii) questões abertas, voltadas à identificação de pontos positivos e sugestões de melhoria.

Para avaliar a efetividade das recomendações foi utilizada a *taxa de acerto por incidência*, que mede a frequência com que um mapa recomendado foi efetivamente acessado pelo usuário na mesma sessão.

$$Taxa\ de\ Acerto = \frac{\sum_{i=1}^N h_i}{N} \quad (6)$$

onde $h_i = 1$ quando o mapa recomendado foi acessado pelo usuário e $h_i = 0$ caso contrário.

4. Resultados

Esta seção apresenta os resultados obtidos a partir da avaliação do sistema NaVISOL com base em dois conjuntos de dados: (i) registros de interação coletados automaticamente durante o uso da plataforma e (ii) respostas de um questionário aplicado aos usuários que participaram dos testes do chatbot.

³O formulário completo utilizado na avaliação está disponível em: <https://forms.gle/oLBGyhPEspZAggZ1A>

Ao todo foram identificados 199 usuários únicos nos registros da plataforma. A coleta ocorreu em quatro etapas experimentais realizadas entre agosto e novembro de 2025, permitindo observar a evolução do sistema à medida que o volume de interações aumentava.

4.1. Resultados Quantitativos

A análise quantitativa concentrou-se na evolução das matrizes de similaridade entre mapas ao longo das etapas experimentais e na avaliação do desempenho do sistema de recomendação.

O experimento foi conduzido em quatro etapas incrementais (40, 80, 120 e 199 usuários), permitindo observar a evolução dos padrões de similaridade à medida que o volume de interações aumentava. Nas etapas iniciais, as matrizes apresentaram elevada esparsidade e relações pontuais entre mapas. Com o aumento do número de usuários, observou-se a gradual formação de agrupamentos mais consistentes, especialmente após a aplicação do SVD, que passou a evidenciar relações latentes entre camadas de mobilidade urbana e infraestrutura pública. As matrizes correspondentes às etapas intermediárias foram omitidas por limitação de espaço e estão disponíveis no repositório do projeto².

As Figuras 3 e 4 apresentam, respectivamente, a matriz de similaridade original e a matriz obtida após a aplicação da decomposição em valores singulares (SVD) na etapa final do experimento, considerando 199 usuários.

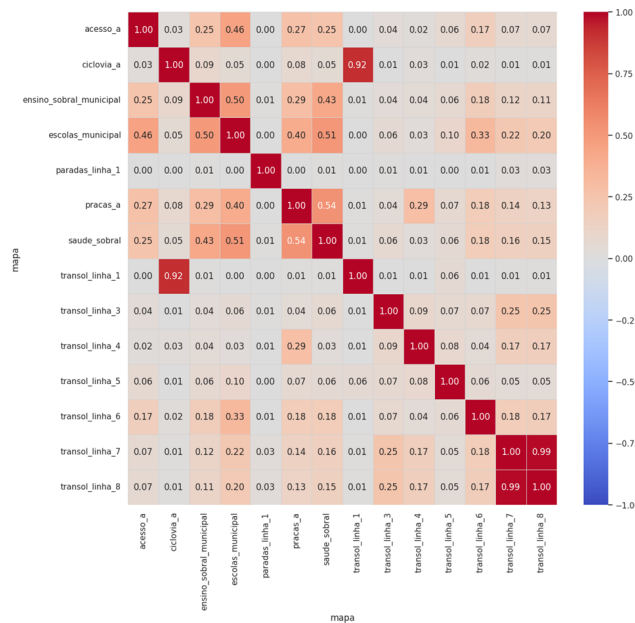


Figura 3. Matriz de similaridade bruta com 199 usuários.

Mesmo com o aumento do número de usuários, a matriz de similaridade original permanece caracterizada por forte esparsidade e pela presença de correlações pontuais entre mapas, sem a formação de agrupamentos temáticos amplos. Esse comportamento já havia sido observado nas etapas anteriores, conforme descrito no estudo completo.

Após a aplicação do SVD, observa-se uma reorganização significativa das relações de similaridade, com a consolidação de dois agrupamentos principais de camadas ge-




Figura 4. Matriz de similaridade após SVD na etapa final (199 usuários).

ográficas. O primeiro está associado à mobilidade urbana, envolvendo diferentes linhas do sistema de transporte coletivo. O segundo reúne camadas relacionadas à infraestrutura urbana e serviços públicos, como escolas, praças, unidades de saúde e acessos urbanos.

Além disso, são evidenciadas conexões transversais entre esses agrupamentos, indicando que usuários interessados em mobilidade urbana tendem também a explorar informações relacionadas a serviços e equipamentos públicos. Esse comportamento sugere que a aplicação da decomposição em valores singulares contribui para revelar relações latentes entre as camadas geográficas, permitindo reduzir os efeitos da esparsidade observada na matriz original e evidenciar padrões de navegação mais consistentes.

4.1.1. Avaliação por Incidência de Uso

A efetividade das recomendações foi avaliada por meio da taxa de incidência de uso, que mede a proporção de recomendações apresentadas pelo sistema que resultaram no acesso posterior ao mapa sugerido.

Os resultados obtidos em cada etapa foram:

- Etapa 1 (40 usuários): 16,67%
- Etapa 2 (80 usuários): 14,29%
- Etapa 3 (120 usuários): 10,53%
- Etapa final (199 usuários): 10,66%

Observa-se que, após as etapas iniciais do experimento, a taxa de incidência tende a se estabilizar em torno de 10%. Embora esses valores possam parecer modestos em termos absolutos, é importante considerar que a métrica adotada baseia-se em ações diretas do usuário, caracterizando um cenário de alta seletividade. Em ambientes com grande volume de informações, como plataformas GIS, taxas de incidência nessa ordem são compatíveis com sistemas de recomendação baseados em *feedback* implícito, indicando que o

modelo é capaz de gerar sugestões relevantes sem interferir excessivamente na experiência do usuário.

Nesse contexto, os resultados indicam comportamento estável do sistema com o crescimento da base de usuários, sugerindo que o modelo baseado em similaridade entre mapas captura padrões relevantes de navegação na plataforma.

4.2. Avaliação da Experiência do Usuário

A avaliação qualitativa foi realizada por meio de um questionário aplicado aos usuários que interagiram com o NaVISOL, totalizando 174 respostas válidas. As perguntas foram avaliadas em escala Likert de cinco pontos, variando de 1 (discordo totalmente) a 5 (concordo totalmente). Para a análise dos resultados, considerou-se como avaliação positiva a soma das respostas *concordo parcialmente* (4) e *concordo totalmente* (5).

Os resultados indicam alto nível de familiaridade dos participantes com interfaces conversacionais: aproximadamente 99% dos respondentes declararam utilizar aplicativos de mensagens instantâneas no cotidiano, enquanto cerca de 88% afirmaram já ter interagido previamente com chatbots em outros contextos.

Em relação à usabilidade do sistema, aproximadamente 63% dos participantes avaliaram positivamente a afirmação de que a interação com o chatbot foi intuitiva, sugerindo que a interface conversacional contribuiu para reduzir a complexidade associada à exploração de dados geográficos em plataformas GIS.

Quanto à capacidade de compreensão das perguntas realizadas pelos usuários, cerca de 48% dos respondentes atribuíram avaliações positivas ao desempenho do chatbot. Embora esse resultado indique funcionamento satisfatório do sistema, ele também evidencia oportunidades de melhoria na interpretação de linguagem natural, especialmente em consultas mais específicas ou formuladas de maneira informal.

A percepção sobre a relevância das recomendações também apresentou resultados majoritariamente positivos: aproximadamente 57% dos participantes consideraram as sugestões fornecidas pelo sistema úteis para suas consultas.

Além disso, cerca de 60% dos respondentes indicaram que as recomendações apresentadas pelo chatbot contribuíram para a descoberta de novos locais ou informações no mapa. Esse resultado reforça o papel do sistema não apenas como mecanismo de consulta, mas também como ferramenta de exploração de informações geográficas dentro da plataforma.

As respostas abertas do questionário reforçam essa interpretação. Entre os aspectos positivos mais mencionados pelos usuários destacam-se a rapidez das respostas, a facilidade de uso e a utilidade das informações fornecidas sobre locais e rotas da cidade. Entre as principais sugestões de melhoria aparecem a ampliação da cobertura de dados geográficos e o aprimoramento da capacidade de compreensão das perguntas formuladas pelos usuários.

5. Conclusões

Este trabalho apresentou o desenvolvimento e a avaliação do NaVISOL, um chatbot integrado a um sistema de recomendação híbrido proposto como camada de mediação inteligente para a plataforma Sobral em Mapas. A solução busca reduzir as barreiras de

usabilidade presentes em sistemas GIS tradicionais, permitindo que usuários consultem informações geográficas e explorem o mapa por meio de linguagem natural.

Os resultados obtidos indicam que o modelo de recomendação baseado em similaridade entre mapas, aliado à decomposição em valores singulares, foi capaz de identificar padrões relevantes de navegação entre camadas geográficas, mesmo em cenários de dados esparsos. A avaliação baseada em incidência de uso demonstrou desempenho consistente do sistema, com taxas de aceitação das recomendações estabilizadas em torno de 10%. Esses resultados são reforçados pela análise qualitativa, na qual a maioria dos usuários avaliou positivamente a usabilidade do sistema, a relevância das recomendações e o potencial do chatbot para auxiliar na descoberta de novas informações geográficas na plataforma.

Na perspectiva da Computação Urbana, este trabalho vai além da implementação algorítmica ao aplicar na prática o conceito de *Data for Good*. O sistema transforma infraestruturas de dados abertos, antes complexas para o público leigo, em ambientes interativos e centrados no cidadão. Por ser agnóstica, essa arquitetura pode ser facilmente replicada em outros municípios, ajudando a democratizar a informação espacial e fortalecendo o engajamento em cidades inteligentes.

Como trabalhos futuros, destacam-se a ampliação da base de usuários para análises longitudinais e a incorporação de novos sinais contextuais no modelo de recomendação. Além disso, para mitigar as limitações de compreensão de linguagem informal observadas durante os testes, planeja-se a exploração de técnicas mais avançadas de representação semântica, integrando grandes modelos de linguagem (LLMs) para tornar a interação com o cidadão ainda mais natural e fluida.

Referências

- Acharya, M., Yadav, S., and Mohbey, K. K. (2023). How can we create a recommender system for tourism? a location centric spatial binning-based methodology using social networks. *International Journal of Information Management Data Insights*, 3(1):100161.
- Azmanstorfer, K., Bartling, M., Haltofová, B., Zurita-Arthos, L., Grubinger-Preiner, J., and Eitzinger, A. (2025). Critical success factors of participatory community planning with geospatial digital participatory platforms. *ISPRS International Journal of Geo-Information*, 14(4).
- Bochanov, M. (2024). From reactive to proactive public management in the age of digital transformation. *Ars Administrandi* (), 16:555–570.
- Domnich, Y. (2022). The impact of product and process innovations on productivity: A review of empirical studies. *Foresight and sti governance*, 16(3):68–82.
- Interaction Design Foundation (2016). What is motivation in ux/ui design? Retrieved November 18, 2025.
- Ji, Y., Gao, S., Nie, Y., Majić, I., and Janowicz, K. (2025). Foundation models for geospatial reasoning: assessing the capabilities of large language models in understanding geometries and topological spatial relations. *International Journal of Geographical Information Science*, pages 1–38.

- Kaiser, Z. A. (2024). Smart governance for smart cities and nations. *Journal of Economy and Technology*, 2:216–234.
- Kotkov, D., Wang, S., and Veijalainen, J. (2017). Improving serendipity and accuracy in cross-domain recommender systems. pages 105–119.
- Liu, F., Chen, J., Yu, J., and Zhong, R. (2025). Next point of interest (poi) recommendation system driven by user probabilistic preferences and temporal regularities. *Mathematics*, 13(8):1232.
- Looyestyn, J., Kernot, J., Boshoff, K., Ryan, J., Edney, S., and Maher, C. (2017). Does gamification increase engagement with online programs? a systematic review. *PLOS ONE*, 12(3):e0173403.
- Luo, H., Zhou, J., Bao, Z., Li, S., Culpepper, J. S., Ying, H., Liu, H., and Xiong, H. (2020). Spatial object recommendation with hints: When spatial granularity matters. In *Proceedings of the 43rd International ACM SIGIR Conference on research and development in information retrieval*, pages 781–790.
- Mansourian, A. and Oucheikh, R. (2024). Chatgeoai: Enabling geospatial analysis for public through natural language, with large language models. *ISPRS International Journal of Geo-Information*, 13(10):348.
- Misuraca, G. and Noordt, C. V. (2020). Ai watch - artificial intelligence in public services. Scientific analysis or review, Policy assessment KJ-NA-30255-EN-N (online), Luxembourg (Luxembourg).
- OECD (2025). *Governing with Artificial Intelligence: The State of Play and Way Forward in Core Government Functions*. OECD Publishing, Paris.
- Ribeiro, M. M. and Segatto, C. I. (2025). Inteligência artificial nas organizações públicas brasileiras: heterogeneidades e capacidades em tecnologia da informação. *Revista de Administração Pública*, 59(1):e2024–0066.
- Sanjaya, W., Calvin, Muhammad, R., Meiliana, and Fajar, M. (2023). Systematic literature review on implementation of chatbots for commerce use. *Procedia Computer Science*, 227:432–438. 8th International Conference on Computer Science and Computational Intelligence (ICCS CI 2023).
- Santos, J. T. (2022). O uso de dados nas cidades brasileiras: uma análise utilizando a macrometrópole paulista. In *Workshop de Computação Urbana (CoUrb)*, pages 57–69. SBC.
- Unrau, R. and Kray, C. (2021). Mining map interaction semantics in web-based geographic information systems (webgis) for usability analysis. *AGILE: GIScience Series*, 2:16.
- Wirtz, B. W., Weyerer, J. C., and Geyer, C. (2019). Artificial intelligence and the public sector—applications and challenges. *International Journal of Public Administration*, 42(7):596–615.
- Zhao, D., Petrov, A., Ivanov, D., Volkov, S., Smith, J., and Wang, J. (2025). Exploring geographic information systems (gis) for smart city analytics.