



UNIVERSIDADE FEDERAL DO CEARÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E DE
COMPUTAÇÃO
MESTRADO ACADÊMICO EM ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO

ALEX DE SOUSA RAMOS

NAVISOL: DESENVOLVIMENTO DE UM CHATBOT COM SISTEMA DE
RECOMENDAÇÃO PARA O MAPA DIGITAL DA CIDADE DE SOBRAL

SOBRAL

2026

AGRADECIMENTOS

A Deus, por sua infinita bondade, bênçãos e por me permitir aprender.

À minha pequena Lia, o amor da minha vida, ainda no ventre de sua mãe.

À minha esposa, Ana Beatriz Rodrigues de Almeida, pelo apoio constante, incentivo e dedicação nas revisões deste trabalho.

Ao meu pai, Odirlei Pessoa Ramos, e à minha mãe, Antônia Elizandra de Sousa Feitoza.

À minha avó Joana Rodrigues Pessoa e ao meu avô Pedro Alexandre Neco de Sousa.

Ao meu irmão, Ian de Sousa Ramos, de quem muito me orgulho.

Ao meu orientador, Prof. Dr. Iális Cavalcante, pelo apoio, dedicação e exemplos que me inspiraram a seguir a docência. Mais do que exercer sua função acadêmica, tem proporcionado oportunidades de acesso a novos níveis de conhecimento que, até então, eu sequer imaginava alcançar.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo apoio financeiro por meio da concessão de bolsa de estudos, fundamental para a realização desta pesquisa e para o desenvolvimento das atividades acadêmicas que possibilitaram a concretização deste trabalho.

Aos meus amigos, que são fonte permanente de suporte, incentivo e conselhos.

A todos os professores, desde o ensino infantil até a graduação, a quem devo este novo degrau do conhecimento que agora alcanço.

Nem tão longe que eu não possa ver
Nem tão perto que eu possa tocar
Nem tão longe que eu não possa crer
Que um dia chego lá.

(Humberto Gessinger)

RESUMO

A crescente demanda da população por acesso rápido, claro e eficiente a serviços e informações públicas, especialmente em contextos urbanos cada vez mais dependentes de tecnologias digitais, torna-se essencial o desenvolvimento de soluções que facilitem a interação do cidadão com bases de dados complexas, como os Sistema de Informação Geográfica (GIS). A disponibilização de grandes volumes de informações em plataformas de mapas interativos, embora promissora, ainda enfrenta limitações de usabilidade, frequentemente resultando em dificuldades de navegação, sobrecarga cognitiva e subutilização dos recursos disponíveis. Nesse contexto, este trabalho propõe o desenvolvimento do Navegador Virtual Inteligente de Sobral (NaVISOL), um agente conversacional baseado em Inteligência Artificial (IA) e Processamento de Linguagem Natural (PLN), implementado com o *framework* Rasa e integrado à plataforma Sobral em Mapas, com o objetivo de viabilizar uma interface mais acessível para consulta e exploração de dados geoespaciais. O sistema incorpora um motor de recomendação híbrido que combina o contexto conversacional, o *feedback* implícito de navegação dos usuários e técnicas de Decomposição em Valores Singulares (SVD) para análise de similaridade entre camadas do mapa, mitigando problemas de esparsidade de dados e promovendo a descoberta proativa de conteúdos relevantes. Para avaliar a eficácia da solução, foram realizadas análises quantitativas baseadas na métrica de incidência de uso das recomendações, bem como uma avaliação qualitativa da experiência do usuário por meio de questionários que abordaram aspectos de usabilidade, compreensão das respostas e percepção de relevância das sugestões fornecidas. Os resultados indicam que a adoção da interface conversacional associada ao sistema de recomendação contribui para uma interação mais intuitiva com o GIS, aumenta a taxa de acesso às camadas recomendadas e favorece a descoberta de novos conteúdos geográficos, evidenciando o potencial do NaVISOL como uma ferramenta para democratizar o acesso às informações urbanas e fortalecer iniciativas de governo digital centradas no cidadão.

Palavras-chave: *Chatbots*. Processamento de Linguagem Natural. Sistemas de Recomendação. Sistemas de Informação Geográfica. Smart Cities.

ABSTRACT

The growing public demand for fast, clear, and efficient access to public services and information, especially in urban contexts increasingly dependent on digital technologies, makes the development of solutions that facilitate citizen interaction with complex databases, such as Geographic Information Systems (GIS), essential. The availability of large volumes of information on interactive mapping platforms, although promising, still faces usability limitations, often resulting in navigation difficulties, cognitive overload, and underutilization of available resources. In this context, this work proposes the development of the Navegador Virtual Inteligente de Sobral (NaVISOL), a conversational agent based on Artificial Intelligence (AI) and Natural Language Processing (NLP), implemented using the Rasa framework and integrated into the Sobral em Mapas platform, with the objective of enabling a more accessible interface for querying and exploring geospatial data. The system incorporates a hybrid recommendation engine that combines conversational context, implicit user navigation feedback, and Singular Value Decomposition (SVD) techniques for similarity analysis among map layers, mitigating data sparsity issues and promoting proactive discovery of relevant content. To evaluate the effectiveness of the solution, quantitative analyses were conducted based on the usage incidence metric of the recommendations, as well as a qualitative assessment of user experience through questionnaires addressing usability aspects, response comprehension, and perceived relevance of the provided suggestions. The results indicate that the adoption of the conversational interface associated with the recommendation system contributes to a more intuitive interaction with GIS, increases access to recommended layers, and fosters the discovery of new geographic content, demonstrating the potential of NaVISOL as a tool to democratize access to urban information and strengthen citizen-centered digital government initiatives.

Keywords: Chatbots. Natural Language Processing. Recommendation Systems. Geographic Information Systems. Smart Cities.

LISTA DE ILUSTRAÇÕES

Figura 1 – Fluxograma PRISMA do processo de seleção de estudos	22
Figura 2 – Ilustração das Etapas do Processamento de Linguagem Natural	30
Figura 3 – Tipologias de Sistemas de Recomendação	35
Figura 4 – Ilustração da decomposição em valores singulares	43
Figura 5 – Ilustração da SVD Truncada	44
Figura 6 – Fluxo de desenvolvimento do <i>chatbot</i>	49
Figura 7 – Representação da Arquitetura do <i>Chatbot</i>	51
Figura 8 – Fluxo do pipeline de Processamento de Linguagem Natural adotado no chatbot	53
Figura 9 – Exemplo de marcação automática no mapa a partir da pergunta do usuário .	55
Figura 10 – Fluxo do sistema de recomendação híbrido baseado em contexto e filtragem colaborativa	56
Figura 11 – Tela de boas-vindas do <i>chatbot</i> NAVISOL, apresentando uma sugestão de interação.	63
Figura 12 – Resposta do <i>chatbot</i> exibindo a rota no mapa e fornecendo uma recomendação de categorias relacionadas.	64
Figura 13 – Matriz de Similaridade Bruta — Etapa 1 (40 usuários).	68
Figura 14 – Matriz de Similaridade com SVD — Etapa 1 (40 usuários).	69
Figura 15 – Matriz de Similaridade Bruta — Etapa 2 (80 usuários).	70
Figura 16 – Matriz de Similaridade com SVD — Etapa 2 (80 usuários).	71
Figura 17 – Matriz de Similaridade Bruta — Etapa 3 (120 usuários).	72
Figura 18 – Matriz de Similaridade com SVD — Etapa 3 (120 usuários).	73
Figura 19 – Matriz de Similaridade Bruta — Etapa final (199 usuários).	75
Figura 20 – Matriz de Similaridade com SVD — Etapa final (199 usuários).	76
Figura 21 – Familiaridade com <i>chatbots</i>	78
Figura 22 – Usabilidade do <i>chatbots</i>	79
Figura 23 – Compreensão das respostas	79
Figura 24 – Relevância das Recomendações	80
Figura 25 – Descoberta de novos lugares	81

LISTA DE TABELAS

Tabela 1 – Construção da sequência de pesquisa	21
Tabela 2 – String de Busca em Inglês com Foco em Chatbots e Sistemas de Recomendação	21
Tabela 3 – Artigos analisados e seus tipos de sistemas de recomendação	24
Tabela 4 – Exemplo de Matriz de Interação (Formato Usuário-Mapa)	59
Tabela 5 – Exemplo de Matriz de Interação (Formato Usuário-Mapa transposta)	59
Tabela 6 – Exemplo de vetores latentes dos mapas após aplicação do SVD (matriz $\mathbf{X}_{\text{mapas}}$)	60
Tabela 7 – Resumo da taxa de incidência por etapa.	76

LISTA DE ABREVIATURAS E SIGLAS

API	Application Programming Interface
BERT	Bidirectional Encoder Representations from Transformers
CB	Baseado em Conteúdo (<i>Content-Based</i>)
CF	Filtragem Colaborativa (<i>Collaborative Filtering</i>)
CNN	Redes Neurais Convolucionais
CX	Sensível ao Contexto (<i>Context-Aware</i>)
GeoAI	Geospatial Artificial Intelligence
GIS	Sistema de Informação Geográfica
GPT	Generative Pre-trained Transformer
HTTP	Hypertext Transfer Protocol
HY	Híbrido (<i>Hybrid</i>)
IA	Inteligência Artificial
IoT	Internet das Coisas
JSON	JavaScript Object Notation
KB	Baseado em Conhecimento (<i>Knowledge-Based</i>)
LLaMA	Large Language Model Meta AI
LLM	Large Language Model
MAE	Erro Absoluto Médio
MAP	Mean Average Precision
NaVISOL	Navegador Virtual Inteligente de Sobral
NDCG	Normalized Discounted Cumulative Gain
NLU	Natural Language Understanding
OpenCV	Open Source Computer Vision Library
PLN	Processamento de Linguagem Natural
POIs	Pontos de Interesse
PPGIS	GIS de Participação Pública
PRISMA	Preferred Reporting Items for Systematic Reviews and Meta-Analyses
RAG	Retrieval-Augmented Generation
REST	Representational State Transfer
RMSE	Raiz do Erro Quadrático Médio
SEPLAG	Secretaria do Planejamento e Gestão

SEUMA	Secretaria do Urbanismo e Meio Ambiente
SVD	Decomposição em Valores Singulares
TICs	Tecnologias da Informação e Comunicação
UFC	Universidade Federal do Ceará

SUMÁRIO

1	INTRODUÇÃO	12
1.1	Contextualização	12
1.2	Objetivos	14
1.2.1	<i>Objetivo Geral</i>	14
1.2.2	<i>Objetivos Específicos</i>	14
1.3	Justificativa e Contribuições	15
1.4	Estado da Arte	15
1.5	Estrutura da Dissertação	17
2	REVISÃO SISTEMÁTICA DE LITERATURA	19
2.1	Protocolo de Pesquisa	19
2.2	Coleta de Dados	20
2.3	CrITÉrios de Elegibilidade	20
2.3.1	<i>CrITÉrios de Inclusão</i>	20
2.3.2	<i>CrITÉrios de Exclusão</i>	20
2.4	EstratÉgia de Busca	21
2.5	Etapas de Seleção e Extração de Dados	21
2.6	SÍntese dos Resultados	22
2.6.1	<i>Tecnologias empregadas na construção dos chatbots</i>	23
2.6.2	<i>Tipos de sistemas de recomendação identificados</i>	23
2.6.3	<i>Principais dificuldades relatadas</i>	26
3	FUNDAMENTAÇÃO TEÓRICA	27
3.1	Processamento de Linguagem Natural	27
3.1.1	<i>Tokenização</i>	27
3.1.2	<i>Análise Léxica</i>	28
3.1.3	<i>Análise Sintática</i>	28
3.1.4	<i>Análise Semântica</i>	29
3.1.5	<i>Análise Pragmática</i>	29
3.1.6	<i>Arquitetura Geral de PLN</i>	30
3.2	Chatbots	30
3.2.1	<i>Plataformas de Desenvolvimento de chatbots</i>	32

3.2.1.1	<i>Dialogflow</i>	32
3.2.1.2	<i>IBM Watson</i>	33
3.2.1.3	<i>Pandorabots</i>	33
3.2.1.4	<i>Microsoft Bot Framework</i>	33
3.2.1.5	<i>Rasa</i>	34
3.3	Sistemas de Recomendação	34
3.3.1	<i>Filtragem Colaborativa</i>	35
3.3.1.1	<i>Métodos Baseados em Vizinhaça</i>	36
3.3.1.2	<i>Métodos Baseados em Modelo</i>	37
3.3.2	<i>Filtragem Baseada em Conteúdo</i>	38
3.3.3	<i>Filtragem Baseada em Conhecimento</i>	38
3.3.4	<i>Sistemas Sensíveis ao Contexto</i>	40
3.3.4.1	<i>Contexto Conversacional</i>	40
3.3.5	<i>Sistemas Híbridos</i>	41
3.3.6	<i>Fontes de Preferência</i>	42
3.3.7	<i>SVD Truncada para Fatoração de Matrizes</i>	42
3.3.7.1	<i>Aplicações da SVD Truncada</i>	43
3.3.7.2	<i>A Representação no Espaço Latente</i>	44
3.3.8	<i>Avaliação de Sistemas de Recomendação</i>	45
3.3.8.1	<i>Métricas de Acurácia</i>	45
3.3.8.2	<i>Métricas Além da Acurácia e a Interpretabilidade</i>	46
4	METODOLOGIA	48
4.1	Análise das Demandas dos Usuários	48
4.2	Configuração do Ambiente	50
4.3	Desenvolvimento do <i>Chatbot</i>	50
4.3.1	<i>Arquitetura de Funcionamento do Chatbot</i>	51
4.3.2	<i>Criação e Configuração do Chatbot</i>	51
4.3.2.1	<i>Pipeline de Processamento de Linguagem Natural</i>	52
4.3.2.2	<i>Políticas de Decisão do Diálogo</i>	54
4.3.3	<i>Integração com o Sobral Mapas</i>	55
4.4	Implementação do Sistema de Recomendação	56
4.4.1	<i>Preparação dos Dados</i>	57

4.4.2	<i>Treinamento</i>	59
4.4.3	<i>Avaliação baseada em incidência de uso</i>	61
4.4.4	<i>Integração das Recomendações no Sistema</i>	62
4.5	Metodologia de Avaliação da Experiência do Usuário	63
4.5.1	<i>Perfil do Usuário</i>	64
4.5.2	<i>Avaliação do Chatbot</i>	65
4.5.3	<i>Feedback Aberto</i>	65
5	RESULTADOS	66
5.1	Resultados Quantitativos do Sistema de Recomendação	66
5.1.1	<i>Análise das Matrizes de Similaridade</i>	67
5.1.1.1	<i>Etapa 1: 40 Usuários</i>	67
5.1.1.2	<i>Etapa 2: 80 Usuários</i>	68
5.1.1.3	<i>Etapa 3: 120 Usuários</i>	71
5.1.1.4	<i>Etapa Final: 199 Usuários</i>	74
5.1.2	<i>Avaliação por Incidência de Uso</i>	75
5.2	Avaliação Qualitativa do Uso do chatbot	77
5.2.1	<i>Perfil dos Respondentes e Familiaridade com Tecnologias Digitais</i>	77
5.2.2	<i>Usabilidade e Facilidade de Uso</i>	78
5.2.3	<i>Compreensão das Respostas do Chatbot</i>	79
5.2.4	<i>Percepção sobre a Relevância das Recomendações</i>	80
5.2.5	<i>Apoio à Descoberta de Novos Locais</i>	81
5.2.6	<i>Percepções Abertas e Sugestões de Melhoria</i>	82
6	CONCLUSÕES E TRABALHOS FUTUROS	85
	REFERÊNCIAS	87
7	QUESTIONÁRIO APLICADO AOS PARTICIPANTES	96

1 INTRODUÇÃO

1.1 Contextualização

A transformação digital tem redefinido fundamentalmente a relação entre cidadãos e a administração pública. No epicentro dessa mudança, o conceito de *Smart Cities* emerge como um paradigma central para o planejamento urbano no século XXI. Esta abordagem propõe o uso intensivo de Tecnologias da Informação e Comunicação (TICs) para otimizar a gestão de recursos urbanos essenciais, como transporte, energia, água e resíduos. O objetivo é duplo: por um lado, aumentar a eficiência operacional da máquina pública e, por outro, elevar a qualidade de vida dos cidadãos, fomentar a transparência e incentivar a participação cívica (KAISER, 2024).

Fundamentalmente, uma *Smart City* opera através da coleta e análise de dados em larga escala. A infraestrutura urbana é progressivamente equipada com uma vasta rede de sensores, câmeras e dispositivos da Internet das Coisas (IoT), que monitoram a cidade em tempo real, desde o fluxo de tráfego e a qualidade do ar até o consumo de energia em edifícios públicos. Esses dados brutos são processados por sistemas de *Big Data* e, cada vez mais, por algoritmos de Inteligência Artificial (IA), que buscam identificar padrões, prever demandas e automatizar respostas, idealmente transformando a gestão urbana de reativa para proativa (BARNES, 2018).

Neste cenário, os Sistema de Informação Geográfica (GIS), comumente apresentados ao público como mapas interativos, emergiram como a infraestrutura tecnológica basilar para essa nova governança. Eles funcionam como o painel de controle da cidade inteligente, permitindo que a administração integre, analise e disponibilize vastos volumes de dados geoespaciais, que vão desde rotas de transporte e zoneamento urbano até a localização de serviços de saúde e indicadores ambientais. A premissa é que, ao dar ao cidadão acesso direto a esses dados, fomenta-se a transparência e a participação (ZHAO *et al.*, 2025).

Contudo, a mera disponibilização de dados complexos não garante seu acesso ou utilidade. A complexidade inerente às interfaces GIS tradicionais, que frequentemente exigem que o usuário navegue por múltiplas camadas, legendas técnicas e filtros, cria uma barreira significativa de usabilidade. Cidadãos sem treinamento técnico especializado em geoprocessamento frequentemente enfrentam uma sobrecarga cognitiva e informacional, subutilizando o potencial dessas plataformas (ATZMANSTORFER *et al.*, 2025).

Fica claro, portanto, que o desafio contemporâneo não é mais apenas a coleta de dados urbanos, mas a mediação eficaz dessa informação para o usuário final. A eficácia de uma

Smart City não se mede pela quantidade de dados em seu GIS, mas pela sua capacidade de traduzir esses dados em valor cívico e governança participativa (MEIJER; BOLÍVAR, 2016). A concepção tradicional do GIS como um repositório passivo falha em endereçar essa barreira. A literatura aponta, assim, para a necessidade de uma evolução: a transição para um GIS de Participação Pública (PPGIS), onde a plataforma se torna uma arena para a mediação e a cocriação de soluções (KAJOSAARI, 2024).

Para enfrentar o desafio da usabilidade em sistemas GIS, o uso de agentes conversacionais, impulsionados por avanços em Processamento de Linguagem Natural (PLN), oferece uma interface mais intuitiva e acessível, permitindo que o usuário simplesmente pergunte em vez de navegar por menus complexos. No entanto, essa abordagem resolve apenas o primeiro nível do problema: a usabilidade da busca transacional. Um *chatbot* puramente reativo, mesmo que utilize modelos de PLN sofisticados, ainda depende que o usuário saiba exatamente o que perguntar, falhando assim em lidar com o segundo e mais complexo desafio, a descoberta de informações (KUSHMITHA *et al.*, 2025).

Um exemplo proeminente dessa iniciativa, e que ilustra perfeitamente este desafio de usabilidade, é o projeto Sobral em Mapas. Esta plataforma, objeto central do presente estudo, foi desenvolvida em colaboração entre a Universidade Federal do Ceará (UFC) e a Prefeitura de Sobral. O projeto serve como um repositório centralizado de convenções cartográficas essenciais, incluindo pontos de interesse, divisões administrativas e infraestrutura.

Em um sistema com diversas informações geográficas como o “Sobral em Mapas”, por exemplo, um usuário interessado em consultar uma rota de ônibus pode desconhecer a existência de uma nova ciclovia ou de pontos de interesse próximos ao seu destino. Para superar essa limitação, torna-se essencial incorporar mecanismos de recomendação capazes de antecipar necessidades e sugerir conteúdos relevantes de forma proativa (KENTERIS *et al.*, 2010). Contudo, a implementação de sistemas de recomendação nesse contexto enfrenta desafios significativos, especialmente em domínios baseados em dados implícitos, onde barreiras como a esparsidade de dados, caracterizada pela escassez de interações registradas entre usuários e itens, e o problema de *cold-start*, que ocorre quando não há informações suficientes sobre novos usuários ou itens para gerar recomendações confiáveis, são recorrentes e comprometem a precisão e a personalização das recomendações (RICCI *et al.*, 2010).

Levando em consideração as lacunas apresentadas, este trabalho propõe o desenvolvimento de um agente conversacional interativo, o NaVISOL, concebido como uma camada de

mediação inteligente para a plataforma “Sobral em Mapas”. A solução proposta opera em duas frentes: (1) responde às consultas transacionais dos usuários por meio de indicações descritivas e marcações dinâmicas na interface do mapa; e (2) endereça o desafio da descoberta de informação através de um motor de recomendação híbrido. Este motor é projetado para coletar o contexto da conversa e o *feedback* implícito do usuário, utilizando uma combinação de análise de similaridade e técnicas de fatoração de matriz para mitigar a esparsidade de dados. O objetivo é transformar a interação reativa em uma experiência proativa, melhorando a usabilidade do sistema e fomentando o engajamento cívico.

1.2 Objetivos

Para validar a arquitetura proposta e avaliar sua eficácia, esta dissertação é guiada por um objetivo geral e cinco objetivos específicos.

1.2.1 *Objetivo Geral*

Desenvolver e avaliar o NaVISOL, um *chatbot* com sistema de recomendação integrado, para facilitar o acesso e promover a descoberta de informações no Mapa Digital da Cidade de Sobral.

1.2.2 *Objetivos Específicos*

1. Analisar as demandas e padrões de interação dos usuários do sistema “Sobral em Mapas” em colaboração com os órgãos da prefeitura.
2. Projetar e implementar o agente conversacional utilizando o *framework* Rasa.
3. Integrar o agente conversacional à plataforma web “Sobral em Mapas”, permitindo a manipulação visual do mapa através de comandos de linguagem natural.
4. Implementar e treinar um sistema de recomendação híbrido que combine o contexto da conversa, o *feedback* implícito e um modelo de similaridade item–item para identificar e sugerir camadas relevantes no mapa.
5. Avaliar a eficácia do sistema de recomendação através de métricas de incidência de uso e a experiência geral do usuário com o NaVISOL por meio de metodologias de avaliação de usabilidade.

1.3 Justificativa e Contribuições

A relevância deste trabalho se manifesta em três dimensões principais:

1. **Contribuição Metodológica (Acadêmica):** A literatura sobre sistemas de recomendação para GIS é menos madura que a de domínios como *e-commerce* ou *streaming* (PEREIRA; JUNIOR, 2025). Esta dissertação contribui com um modelo prático para este domínio, notavelmente pela proposição e uso de *feedback* implícito. A aplicação de Decomposição em Valores Singulares (SVD) para modelar esse comportamento em dados esparsos representa uma contribuição metodológica para o campo de sistemas de recomendação contextuais e de domínio específico.
2. **Contribuição Tecnológica (Artefato):** O NaVISOL é apresentado como um artefato de *software* funcional. A arquitetura que integra uma plataforma de PLN *open-source* (Rasa), um sistema de recomendação híbrido e uma interface GIS é, por si só, uma contribuição de engenharia.
3. **Contribuição Social e Aplicada (Impacto):** Em alinhamento com os objetivos da administração pública e em resposta direta às necessidades da Prefeitura de Sobral, o NaVISOL tem o potencial de impacto social direto. Ao democratizar o acesso aos dados urbanos de Sobral, o sistema promove a inclusão digital, a transparência governamental e auxilia o cidadão a exercer seu “direito à cidade”, utilizando a infraestrutura de dados públicos de forma mais plena e consciente.

1.4 Estado da Arte

As inovações tecnológicas têm desempenhado um papel significativo na busca por maior comodidade, otimização, produtividade e gestão de tempo na vida das pessoas (DOMNICH, 2022). Dentro deste cenário, os agentes conversacionais têm ganhado destaque como uma das tecnologias mais inovadoras, buscando melhorar o comportamento e a eficiência na prestação de serviços em diversas áreas (SANJAYA *et al.*, 2023). Uma das áreas de maior impacto e, simultaneamente, maior desafio para esta transformação é a administração pública. A adoção de IA neste setor tem sido impulsionada pela busca por eficiência e pela necessidade premente de aproximar o cidadão das infraestruturas digitais de governo, tornando os serviços mais acessíveis e transparentes (RIBEIRO; SEGATTO, 2025).

A literatura sobre IA aplicada ao setor público, contudo, evidencia um predomínio

claro de sistemas reativos. Estes sistemas são concebidos essencialmente para otimizar tarefas existentes, respondendo a solicitações pontuais e fornecendo informação sob demanda. Como mostra Bochanov (2024), os agentes conversacionais utilizados atualmente no setor público atuam, em grande parte, em funções transacionais, tais como responder perguntas frequentes ou auxiliar no preenchimento de formulários. Esta abordagem, centrada na automação de tarefas, limita a interação a um fluxo linear de pergunta-resposta e representa uma etapa inicial da adoção de IA, ainda distante de uma mediação verdadeiramente inteligente (MISURACA; NOORDT, 2020).

Em oposição direta a essa abordagem, a investigação recente tem enfatizado o potencial dos sistemas proativos. Estes sistemas não apenas respondem, mas são capazes de antecipar necessidades, analisar padrões de comportamento e sugerir possibilidades antes mesmo de o usuário as formular (WIRTZ *et al.*, 2019). Esta capacidade preditiva é amplamente reconhecida como a próxima fronteira para os serviços públicos. Todavia, a literatura aponta que a maior parte destas aplicações preditivas tem sido dirigida a processos internos, como análise de políticas ou gestão administrativa, como visto em OECD (2025), e não à experiência do usuário final. Identifica-se, assim, uma lacuna crítica entre o potencial da IA proativa e sua concretização em interfaces voltadas ao cidadão.

Estudos recentes sobre Geospatial Artificial Intelligence (GeoAI) mostram que Large Language Model (LLM) continuam a enfrentar limitações significativas na interpretação de relações espaciais, como distância, topologia e localização relativa, devido à natureza vaga da linguagem natural em contraste com a estrutura rígida dos dados geoespaciais (MANSOURIAN; OUCHEIKH, 2024). Por esta razão, grande parte dos agentes conversacionais neste domínio segue o paradigma de “comando e controle”, no qual o usuário formula instruções explícitas. Estudos recentes em GeoAI mostram que, mesmo quando integrados a modelos de linguagem, esses sistemas continuam a depender de comandos estruturados, restringindo a interação a um nível operacional e limitando a exploração e a descoberta espontânea de dados (JI *et al.*, 2025).

No campo da recomendação espacial, observa-se uma limitação semelhante que espelha o desafio da GeoAI. A esmagadora maioria da literatura tem se concentrado em Pontos de Interesse (POIs). Trabalhos como Liu *et al.* (2025) focam em recomendar restaurantes, atrações turísticas ou estabelecimentos comerciais, reforçando a predominância de abordagens voltadas a locais de consumo e visitação. Esta abordagem, embora bem-sucedida, negligencia o potencial de recomendar entidades mais abstratas e complexas, como camadas de informação

geográfica, que representam fenômenos como densidade populacional, zoneamento urbano ou distribuição de serviços públicos. Recomendar camadas exige um tipo de inferência mais sofisticado, capaz de lidar com relações latentes entre dados complexos. Trabalhos como Luo *et al.* (2020) demonstram, por exemplo, que mesmo a recomendação de objetos espaciais em múltiplas granularidades já requer modelos capazes de capturar hierarquias e relações espaciais implícitas, evidenciando a complexidade adicional necessária quando se pretende recomendar camadas temáticas completas.

Paralelamente a estes desafios técnicos, o envolvimento do usuário constitui outro eixo crítico. A interação prolongada e significativa com sistemas digitais depende de mecanismos motivacionais. A motivação extrínseca, amplamente explorada pela gamificação, tem sido explorada em Interaction Design Foundation (2016), mas frequentemente resulta num envolvimento superficial, dependente de estímulos externos. Em contraste, a motivação intrínseca, ligada à curiosidade genuína e ao desejo de descoberta, tende a gerar experiências mais sustentáveis (LOOYESTYN *et al.*, 2017).

Para fomentar essa motivação intrínseca, os sistemas de recomendação assumem um papel central como “catalisadores da serendipidade”, isto é, mecanismos capazes de surpreender o usuário com conteúdos relevantes que ele ainda não sabia precisar (KOTKOV *et al.*, 2017). Para alcançar esse efeito sem introduzir interrupções na experiência do usuário, estudos sobre *feedback* implícito em ambientes geoespaciais mostram que é possível inferir preferências a partir de comportamentos observados, como ações de zoom, pan e seleção de camadas (WEAKLIAM *et al.*, 2005).

1.5 Estrutura da Dissertação

Esta dissertação está organizada em seis capítulos, incluindo esta introdução.

Capítulo 2 – Revisão Sistemática da Literatura: Apresenta uma síntese dos principais trabalhos sobre *chatbots* integrados a sistemas de recomendação. São descritos os passos da busca, critérios de elegibilidade, extração e sumarização dos dados.

Capítulo 3 – Fundamentação Teórica: Reúne os conceitos necessários para o desenvolvimento do trabalho, incluindo Processamento de Linguagem Natural, arquiteturas de *chatbots* e sistemas de recomendação.

Capítulo 4 – Metodologia: Descreve o método adotado no desenvolvimento do NaVISOL. Apresenta os cenários e requisitos, a arquitetura do sistema, a preparação do ambiente,

a implementação do *chatbot* e o treinamento do sistema de recomendação.

Capítulo 5 – Resultados: Expõe os resultados obtidos na avaliação do sistema, incluindo métricas do recomendador e dados da avaliação da experiência dos usuários.

Capítulo 6 – Conclusões e Trabalhos Futuros: Resume as contribuições alcançadas, responde aos objetivos da pesquisa e apresenta propostas para a evolução do NaVISOL.

2 REVISÃO SISTEMÁTICA DE LITERATURA

A revisão sistemática da literatura é uma metodologia rigorosa que visa identificar, avaliar e sintetizar, de forma transparente, os estudos relevantes sobre uma questão de pesquisa específica. Neste trabalho, a revisão teve como foco mapear e analisar a produção científica recente relacionada ao desenvolvimento de *chatbots* integrados a sistemas de recomendação, considerando suas arquiteturas, tecnologias empregadas, tipos de recomendação adotados, benefícios relatados, desafios enfrentados e a interação dos usuários com essas soluções.

Para assegurar a qualidade metodológica, adotou-se um protocolo estruturado baseado nas diretrizes do Preferred Reporting Items for Systematic Reviews and Meta-Analyses (PRISMA)(MOHER *et al.*, 2009), que orientam a condução e o relato de revisões sistemáticas. O processo foi apoiado pela ferramenta Parsifal, utilizada para auxiliar na organização do protocolo e no gerenciamento das etapas de triagem e extração dos dados, favorecendo a rastreabilidade e a transparência metodológica. A busca foi direcionada a bases de dados científicas consolidadas e abrangeu publicações entre 2019 e 2025, garantindo atualidade e relevância dos resultados obtidos.

2.1 Protocolo de Pesquisa

Este estudo é guiado a partir da seguinte pergunta central: “Quais são as arquiteturas, tecnologias e desafios predominantes no desenvolvimento de *chatbots* integrados a sistemas de recomendação para fornecer recomendações personalizadas aos usuários?”.

Para apoiar a investigação e permitir uma análise mais aprofundada do tema, foram elaboradas seis perguntas secundárias que complementam a questão principal. As seis perguntas são:

- Quais são os principais tipos de arquiteturas utilizadas no desenvolvimento de *chatbots* com funcionalidades de recomendação personalizada?
- De que forma os *chatbots* têm sido integrados a sistemas de recomendação, considerando diferentes técnicas?
- Quais são os principais tipos de sistemas de recomendação utilizados em conjunto com *chatbots*?
- Quais benefícios são percebidos na utilização de *chatbots* com recursos de recomendação em diferentes contextos de aplicação?

- Quais são os principais desafios enfrentados na implementação e adoção de *chatbots* recomendadores em ambientes reais?
- Como os usuários interagem e avaliam a experiência com *chatbots* que oferecem recomendações personalizadas?

2.2 Coleta de Dados

Para a seleção dos artigos utilizados nesta pesquisa, foram consultadas bases de dados científicas eletrônicas. A busca foi realizada em sete plataformas, conforme listado a seguir:

1. ACM Digital Library
2. IEEE Xplore Digital Library
3. Scientific Electronic Library Online (SciELO)
4. Scopus
5. ScienceDirect
6. SpringerLink

2.3 Critérios de Elegibilidade

2.3.1 Critérios de Inclusão

Foram incluídos estudos que atenderam aos seguintes critérios:

- Artigos revisados por pares;
- Estudos publicados entre janeiro de 2019 e junho de 2025;
- Trabalhos redigidos em inglês ou português;
- Artigos com foco na aplicação de inteligência artificial conversacional em sistemas de recomendação;
- Artigos que apresentem evidências práticas, arquiteturas ou abordagens aplicadas.

2.3.2 Critérios de Exclusão

Foram excluídos estudos que se enquadraram em um ou mais dos seguintes critérios:

- Título, resumo ou texto completo não relevantes para as questões de pesquisa;
- Trabalhos puramente teóricos, sem aplicação prática;

- Teses, dissertações, capítulos de livros, cartas ao editor, relatórios, resenhas ou estudos de revisão/metanálise;
- Artigos com texto completo indisponível;
- Trabalhos publicados em outras línguas que não sejam inglês ou português;
- Estudos publicados antes de 2019.

2.4 Estratégia de Busca

O método de busca de fontes para a pesquisa foi baseado na aplicação de *strings* de pesquisa construídas a partir do contexto do estudo, incluindo palavras-chave principais e seus respectivos sinônimos. As buscas foram realizadas em bases de dados eletrônicas científicas previamente selecionadas. A estratégia de busca foi organizada em duas categorias principais de termos: *chatbots* e *recommender systems*.

Para ampliar a abrangência e aumentar a precisão dos resultados, foram incorporados sinônimos e variações semânticas de cada termo. Os termos utilizados na construção da sequência de pesquisa estão descritos na Tabela 1.

Tabela 1 – Construção da sequência de pesquisa

Termos de Pesquisa	Sinônimos
Chatbots	Conversational Agents, Virtual Assistants, Conversational AI
Recommender Systems	Recommendation Systems, Personalized Recommendation, Collaborative Filtering, Content-based Recommendation

A *string* de busca foi construída com base nos termos definidos e aplicada nas bases de dados selecionadas. A estratégia completa de busca utilizada encontra-se descrita na Tabela 2.

Tabela 2 – String de Busca em Inglês com Foco em Chatbots e Sistemas de Recomendação

```
("chatbots"OR "conversational agents"OR "virtual assistants"OR "conversational AI") AND ("recommender systems"OR "recommendation systems"OR "personalized recommendation"OR "collaborative filtering"OR "content-based recommendation")
```

2.5 Etapas de Seleção e Extração de Dados

Após o levantamento inicial nas bases de dados, com o auxílio da ferramenta Parsifal, foi possível estruturar o formulário para extração das informações. Inicialmente, todos os títulos

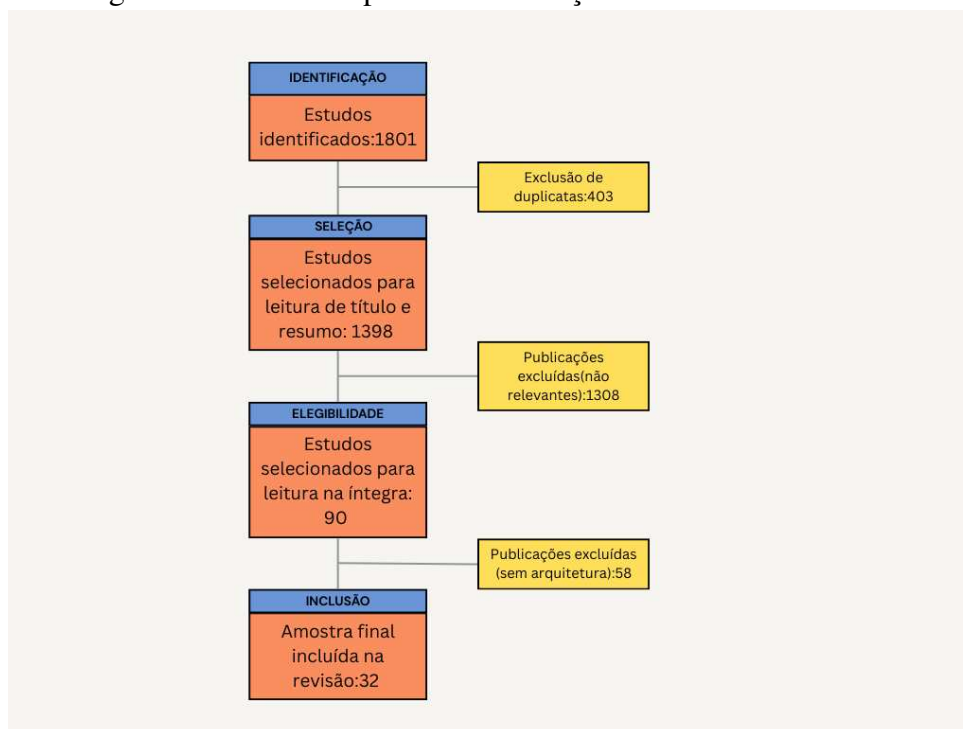
e resumos dos artigos foram avaliados com base nos objetivos principais da pesquisa, com o propósito de identificar os estudos mais relevantes. Para apoiar esse processo, utilizou-se uma planilha local contendo os seguintes campos: ID (contador sequencial para identificação do artigo), Título, Ano de Publicação, Local de Publicação, Base de Dados e Link da Publicação.

Na sequência, realizou-se a remoção de duplicatas com o apoio da ferramenta Parsifal, assegurando que apenas uma versão de cada artigo permanecesse registrada, mesmo que tivesse sido recuperado em mais de uma base de dados. Essa etapa foi essencial para garantir a consistência e a organização do processo de análise.

Posteriormente, os estudos elegíveis foram lidos integralmente por dois pesquisadores, de forma independente. As eventuais divergências entre as avaliações foram discutidas e resolvidas, resultando na seleção da amostra final de artigos para a extração dos dados.

Um resumo das etapas realizadas pode ser observado na Figura 1.

Figura 1 – Fluxograma PRISMA do processo de seleção de estudos



Fonte: Elaborado pelo autor (2025).

2.6 Síntese dos Resultados

A revisão sistemática da literatura resultou na análise de 32 artigos finais que exploram *chatbots* em diferentes domínios, variando desde saúde, turismo, educação e entretenimento até comércio eletrônico e serviços financeiros. Os estudos investigam tanto aspectos tecnológicos

da construção dos agentes conversacionais quanto as técnicas de recomendação utilizadas para gerar sugestões personalizadas. A seguir, apresentamos uma síntese em três eixos: tecnologias empregadas, tipos de sistemas de recomendação e principais dificuldades relatadas.

2.6.1 *Tecnologias empregadas na construção dos chatbots*

Entre os modelos mais recorrentes estão arquiteturas baseadas em *transformers*, com destaque para o Bidirectional Encoder Representations from Transformers (BERT) e suas variações, frequentemente empregados em tarefas de classificação de intenções, análise de sentimentos, similaridade semântica e inferência em cenários de *zero-shot learning*, bem como *frameworks* como o Rasa, utilizados para integrar esses modelos a mecanismos de diálogo e gerenciamento de conversação.

Modelos de larga escala como Generative Pre-trained Transformer (GPT)-3, GPT-4, Google Gemini e Large Language Model Meta AI (LLaMA) também aparecem como base de diversos sistemas, em muitos casos associados a estratégias de Retrieval-Augmented Generation (RAG) e GraphRAG, que permitem a recuperação de informações externas estruturadas e o enriquecimento do diálogo com respostas contextualizadas. O uso de *embeddings* semânticos é recorrente, tanto para mapeamento de intenções quanto para a construção de representações vetoriais que apoiam a busca semântica e a organização do conhecimento.

Além disso, observa-se a adoção de arquiteturas híbridas, nas quais módulos baseados em regras são combinados a modelos de linguagem, especialmente em domínios sensíveis como saúde e educação, garantindo maior controle sobre as respostas. Outro aspecto relevante é a incorporação de abordagens multimodais, integrando PLN a visão computacional e reconhecimento de fala. Nesse contexto, ferramentas como Open Source Computer Vision Library (OpenCV) e MediaPipe, aliadas a modelos de *speech-to-text* e arquiteturas de Redes Neurais Convolucionais (CNN), permitem que *chatbots* reconheçam voz, emoções e imagens, ampliando a naturalidade e a interatividade das conversas.

2.6.2 *Tipos de sistemas de recomendação identificados*

Na Tabela 3, são utilizados acrônimos para indicar os tipos de sistemas de recomendação empregados nos 32 artigos finais. As siglas correspondem a:

- Baseado em Conteúdo (*Content-Based*) (CB);
- Filtragem Colaborativa (*Collaborative Filtering*) (CF);

- Baseado em Conhecimento (*Knowledge-Based*) (KB);
- Sensível ao Contexto (*Context-Aware*) (CX);
- Híbrido (*Hybrid*) (HY);

Tabela 3 – Artigos analisados e seus tipos de sistemas de recomendação

Título	Tipo
A Domain Specific Students' Assistance System For The Provision Of Instructional Feedback (OBIONWU <i>et al.</i> , 2023)	CB
A Multilingual Mental Health Support Chatbot with Regional Language Capabilities Based On the AMER Model (AMIRTHAVARSHINI <i>et al.</i> , 2025)	HY (CB + CF + CX)
AI-Powered Chat Agent: Revolutionizing Online Shopping (BABU <i>et al.</i> , 2024)	HY (CB + CF)
Chat-Bot Assisted Recommendation Platform for Computers and Repair Services (THIRIMANNE <i>et al.</i> , 2023)	HY (CB + CF)
Comprehensive Mobile Solution for Personalized Healthcare Services using Enhanced AI (MANIKANDAN <i>et al.</i> , 2025)	HY (CB + CF + CX)
Cooking and Food Information Chatbot System using GPT-3 (SAFITRI <i>et al.</i> , 2023)	KB
Emotion aware Smart Music Recommender System using Two Level CNN (KRUPA <i>et al.</i> , 2020)	CX
Enhancing Personalized Financial Advisory Application with Generative AI and Chatbot(SUCHONWANICH <i>et al.</i> , 2024)	HY (KB + CX)
Escort – Natural Language Processing Based University Students Guidance System (SRINIVASAN <i>et al.</i> , 2022)	HY (KB + CX)
Guiding Students to Their Future Paths Through Website (PAVITHRA <i>et al.</i> , 2025)	HY (KB + CX)
HealthAssistantBot: A Personal Health Assistant for the Italian Language (POLIGNANO <i>et al.</i> , 2020)	HY (CB + KB)
Implementing a Chatbot Music Recommender System based on User Emotion (MATHEW <i>et al.</i> , 2023)	HY (CB + CF + CX)

Título	Tipo
Innovative Approaches in Predictive Analysis and Personalized Online Shopping Recommendations with AI Powered-Chat (AHAMED <i>et al.</i> , 2025)	HY (CB + CF)
Intelligent Movie Recommendation Platform with AI-Driven Recommendation (MOL <i>et al.</i> , 2024)	HY (CB + CF + CX)
Medisense: An Advanced Health Tech Application Using Generative AI (GONSALVES <i>et al.</i> , 2024)	HY (KB + CX)
Mobile Application for the Intelligent Management of Small Shops using the GPT-4 Model (SAKUDA <i>et al.</i> , 2024)	KB
Multimodal Conversational Bot for Multilingual Personalized Song Recommendation (KEERTHANA; REKHA, 2024)	HY (CB + CF + CX)
Ontology Based Restaurant Recommendation Approach (BANDARA; RANATHUNGA, 2023)	KB
RECBOT: Virtual Museum navigation through a Chatbot assistant and personalized Recommendations (TSITSEKLIS <i>et al.</i> , 2023)	HY (CB + CF + KB)
Recipe Recommendation Chatbot Based on Low FODMAP Dietary Knowledge Graph (TURHAN; BACAKSIZ, 2024)	KB
RetailGPT: A Fine-Tuned LLM Architecture for Customer Experience and Sales Optimization (SHAREEF <i>et al.</i> , 2024)	HY (CB + CF + CX)
Sellybot: Conversational Recommender System Based on Functional Requirements (SOLECHAH <i>et al.</i> , 2022)	KB
ShopSavvy – Empowering Local Commerce Through Online Price Comparison with AI Integration (MAGAR <i>et al.</i> , 2024)	HY (CB + CX)
Smart AI Chatbots for Tailored Nutrition and Fitness Guidance (SASIKALA <i>et al.</i> , 2025)	HY (CB + CX)
Smart Travel Assistance using Machine Learning and Generative Artificial Intelligence (SASIKALA <i>et al.</i> , 2025)	HY (KB + CX)
Survey Shield: Safeguarding Healthcare and Diagnostic Assistant (RAHUL <i>et al.</i> , 2025)	HY (KB + CB)

Título	Tipo
Symptoms Based Disease Diagnosis and Treatment Recommendation (AGARWAL <i>et al.</i> , 2021)	HY (KB + CB)
Tourism Chatbot Framework: Enhancing Visitor Experience Through GraphRAG and AI Chatbot (KRATAITHONG <i>et al.</i> , 2025)	HY (KB + CX)
Trip Craft: Personalized Travel Recommendation Bot (MURUGAN <i>et al.</i> , 2024)	HY (CB + CX)
User Linguistic Style Awareness and Interest-Driven Conversational Recommender Systems (LSAID) (DU <i>et al.</i> , 2024)	HY (CB + KB + CX)
Using AI and Natural Language Processing to Enhance Consumer Banking Decision-Making (TEMARA <i>et al.</i> , 2024)	HY (KB + CX)
Virtual Stylist: Outfit Try-on and Personalized Fashion Advice (UPADHYAY <i>et al.</i> , 2025)	HY (CB + CX)

De modo geral, observa-se uma predominância das abordagens híbridas, que combinam múltiplas técnicas para aumentar a precisão e a personalização. Os sistemas baseados em conhecimento aparecem com frequência em domínios específicos como saúde, nutrição e educação, enquanto os contextuais se destacam em cenários dinâmicos, como música, turismo e moda. Assim, a síntese revela uma tendência clara de integração de técnicas, em busca de maior robustez e adaptabilidade dos sistemas de recomendação aplicados em *chatbots*.

2.6.3 Principais dificuldades relatadas

Apesar do avanço das soluções propostas, os artigos analisados apresentam dificuldades recorrentes. Entre elas, destacam-se problemas de dados, como esparsidade, *cold-start* e limitações de bases pequenas, além de vieses em avaliações públicas. Também foram relatados desafios na incorporação de múltiplos sinais contextuais (emoções, clima, localização, inventário), que aumentam a complexidade e o risco de sobreajuste. Outro obstáculo frequente é a orquestração de arquiteturas híbridas, envolvendo LLM, grafos de conhecimento, filtragem colaborativa e visão computacional em ambientes de baixa latência. Questões éticas e regulatórias, incluindo privacidade de dados sensíveis e explicabilidade das recomendações, também aparecem como barreiras. Finalmente, vários trabalhos apontam a falta de métricas padronizadas e a dificuldade de conduzir estudos longitudinais que validem a eficácia dos sistemas.

3 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta um levantamento bibliográfico abrangente voltado aos principais eixos temáticos que sustentam o desenvolvimento deste trabalho. São explorados conceitos e avanços relacionados a *chatbots*, incluindo os principais *frameworks* para seu desenvolvimento, fundamentos e técnicas de processamento de linguagem natural e abordagens em sistemas de recomendação. A partir dessa revisão, busca-se construir a base teórica necessária para a integração dessas áreas, identificando oportunidades e lacunas na literatura que orientem a proposta e implementação da solução desenvolvida.

3.1 Processamento de Linguagem Natural

PLN é uma área da inteligência artificial dedicada à comunicação entre humanos e computadores por meio da linguagem. Seu objetivo central é permitir que máquinas interpretem, compreendam e produzam textos ou falas de forma semelhante à comunicação humana (KESELJ, 2009). Desde os anos 1950, o PLN evoluiu de métodos baseados em regras para técnicas estatísticas e, atualmente, utiliza modelos de aprendizado profundo, que possibilitam lidar com a complexidade e a ambiguidade da linguagem natural (BARBOSA *et al.*, 2017).

O PLN organiza-se em diferentes níveis de análise: fonético-fonológico (sons), morfológico (palavras), sintático (estrutura), semântico (significado) e pragmático (contexto) (GONZALEZ; LIMA, 2003). A operacionalização desses níveis se dá por meio de um conjunto de etapas processuais que serão detalhadas nas subseções seguintes, abordando desde a tokenização até a análise pragmática, com foco em seus objetivos, métodos e aplicações em sistemas modernos.

3.1.1 Tokenização

A tokenização é a etapa que converte um texto contínuo em unidades menores chamadas *tokens*, que podem ser palavras, subpalavras ou caracteres. Essa segmentação é fundamental para transformar a linguagem natural, rica e complexa, em elementos processáveis pelos algoritmos de PLN. Sem a tokenização, seria inviável estruturar o texto para análises posteriores, já que a linguagem humana não possui fronteiras fixas entre unidades de significado (KESELJ, 2009).

As técnicas variam desde métodos simples, que separam tokens por espaços e pon-

tuações, até abordagens avançadas que lidam com línguas morfologicamente complexas. Em modelos modernos, prevalecem métodos baseados em subpalavras, como *Byte Pair Encoding (BPE)* e *WordPiece*, capazes de decompor palavras desconhecidas em partes menores e reutilizáveis. Essas técnicas são especialmente úteis em sistemas de tradução automática e em modelos de larga escala, garantindo maior robustez e eficiência (PINHEIRO *et al.*, 2022).

3.1.2 *Análise Léxica*

A análise léxica busca normalizar o vocabulário, reduzindo a variabilidade morfológica que surge a partir de diferentes flexões das palavras. Seu objetivo é associar termos que compartilham um mesmo núcleo semântico, permitindo que o sistema trate variantes como “falar”, “falando” e “falei” de forma uniforme. Essa padronização é essencial para simplificar o espaço de busca e aumentar a consistência dos dados processados (KESELJ, 2009).

As principais técnicas são o stemming e a lematização. O stemming aplica regras heurísticas para truncar palavras e obter radicais comuns, sendo rápido, mas impreciso, pois pode reduzir palavras distintas a uma mesma forma. Já a lematização utiliza dicionários e análises gramaticais para mapear termos à sua forma canônica ou lema, garantindo maior precisão (MANNING *et al.*, 2008). Embora mais custosa, essa técnica é amplamente usada em motores de busca e tradutores automáticos. Mesmo com os avanços dos *embeddings* contextuais, que capturam relações morfológicas implicitamente, a análise léxica ainda é importante em sistemas com recursos limitados ou que exigem maior controle linguístico (BALAKRISHNAN; LLOYD-YEMOH, 2014).

3.1.3 *Análise Sintática*

A primeira etapa da análise sintática é a etiquetagem de classes gramaticais, ou simplesmente POS tagging. Essa tarefa consiste em atribuir a cada palavra de uma sentença sua categoria gramatical correspondente, como substantivo, verbo, adjetivo ou advérbio. O POS tagging é crucial não apenas como um fim em si, mas como um pré-requisito para processos mais avançados, pois resolve ambiguidades lexicais e fornece os blocos de construção para a análise estrutural. Historicamente, essa tarefa era realizada por métodos estatísticos como os Modelos Ocultos de Markov (HMM), mas abordagens modernas baseadas em redes neurais recorrentes e Transformers alcançaram um desempenho muito superior (KESELJ, 2009).

Com as palavras já etiquetadas, a análise avança para o parsing, que busca decifrar

a estrutura gramatical completa da sentença. Existem duas abordagens dominantes para essa tarefa. A análise de constituintes segmenta a sentença em sintagmas aninhados, como sintagmas nominais e verbais, formando uma árvore que representa a hierarquia frasal. Já a análise de dependência foca nas relações assimétricas entre as palavras, criando um grafo onde cada termo dependente se conecta a uma palavra principal, ou head. Essa segunda abordagem é especialmente útil para extração de informação, pois revela de forma explícita as relações funcionais, como quem é o sujeito da ação e qual é o objeto (MANNING; SCHÜTZE, 1999).

3.1.4 Análise Semântica

A análise semântica busca compreender o significado expresso no texto, lidando com ambiguidades e polissemias. Diferente da análise sintática, que foca na estrutura, a semântica concentra-se no conteúdo, permitindo que sistemas associem palavras e frases a representações de sentido. Essa etapa é fundamental para tarefas como tradução automática, análise de sentimentos e extração de informações (MANNING; SCHÜTZE, 1999).

Historicamente, surgiram os word embeddings estáticos, como Word2Vec (MIKOLOV *et al.*, 2013) e GloVe (PENNINGTON *et al.*, 2014), que representam palavras como vetores densos em um espaço semântico. Apesar de revolucionários, esses modelos atribuem apenas um vetor fixo por palavra, independentemente do contexto. O avanço veio com os embeddings contextuais, baseados em arquiteturas Transformer, como o BERT (DEVLIN *et al.*, 2019), que produzem representações diferentes para cada ocorrência da palavra conforme o contexto.

3.1.5 Análise Pragmática

A análise pragmática trata da linguagem em uso, considerando o contexto, a intenção comunicativa e o conhecimento compartilhado entre falante e ouvinte. Diferente da semântica, que busca o significado literal, a pragmática foca no que se quer dizer em determinada situação. Essa etapa é a mais complexa, pois exige a capacidade de modelar aspectos do mundo real (BARBOSA *et al.*, 2017).

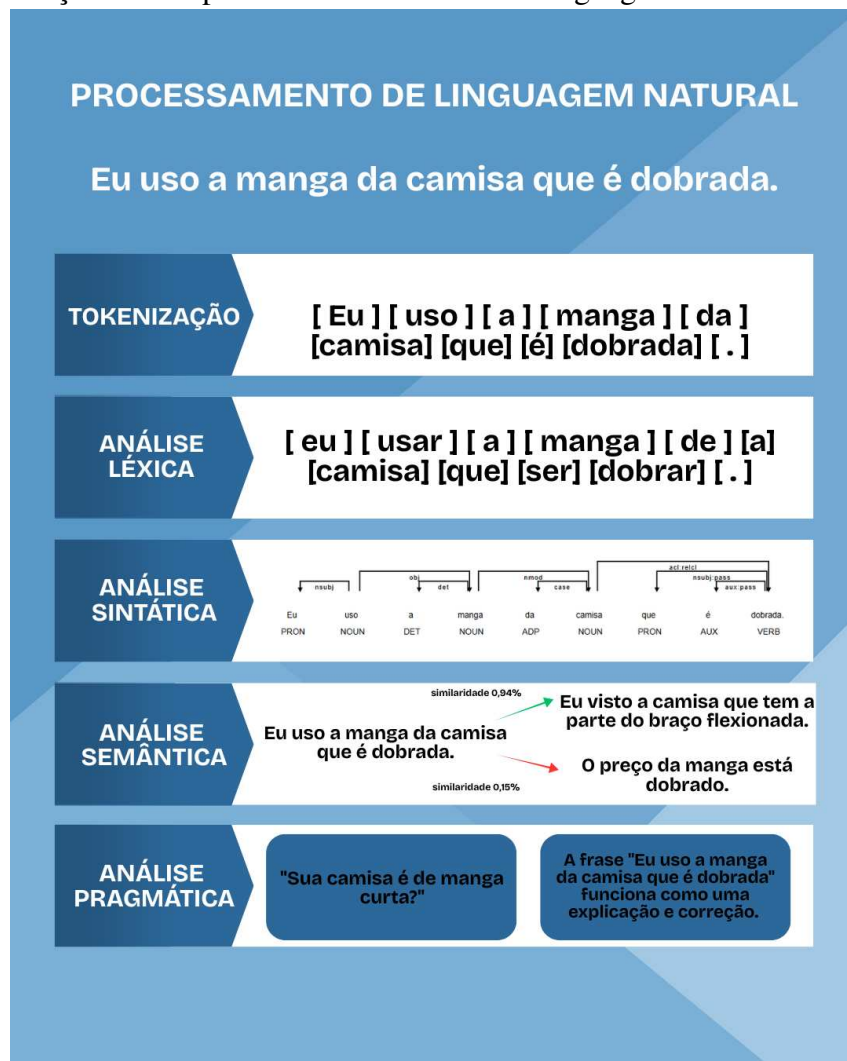
Entre suas técnicas, destacam-se a resolução de anáforas e correferências, essencial para manter a coesão textual; a análise do discurso, que organiza informações ao longo de diálogos e narrativas; e a detecção de sarcasmo, que exige inferências sobre incongruências entre a expressão literal e a intenção real (SUKTHANKER *et al.*, 2020). Essas tarefas são especialmente importantes em aplicações de *chatbots* e assistentes virtuais, nos quais compreender implicações

contextuais é determinante para interações naturais.

3.1.6 Arquitetura Geral de PLN

Concluindo a apresentação das fases de PLN, a Figura 2 serve como uma síntese visual que unifica os conceitos abordados. Ela demonstra, por meio de um exemplo prático, como as diferentes camadas de análise operam de forma interdependente para transformar uma sentença ambígua em uma interpretação contextualizada, consolidando a teoria apresentada.

Figura 2 – Ilustração das Etapas do Processamento de Linguagem Natural



Fonte: Elaborado pelo autor

3.2 Chatbots

Nos últimos anos, o avanço da IA tem impulsionado transformações significativas em diversos setores, e uma de suas aplicações mais notáveis é o desenvolvimento de *chatbots*. Esses

sistemas são projetados para interagir com os usuários de forma conversacional, oferecendo suporte, informações e respostas personalizadas em tempo real. Segundo Liao *et al.* (2023), eles podem ser classificados em dois grandes grupos: sistemas de “chit-chat”, voltados para conversas abertas sem um objetivo específico, e sistemas de diálogo orientados a tarefas, que auxiliam os usuários na execução de atividades concretas, como assistentes pessoais.

Um agente conversacional pode ser definido como a aplicação de técnicas de IA, especialmente do PLN e do Aprendizado de Máquina, para possibilitar interações entre humanos e computadores por meio de linguagem natural. Os primeiros sistemas baseavam-se em regras fixas e bancos de respostas pré-programados. Já os avanços recentes em redes neurais profundas e modelos de linguagem de larga escala possibilitam que os *chatbots* não apenas reconheçam intenções, mas também produzam respostas contextualizadas, adaptando-se dinamicamente ao diálogo (VASWANI *et al.*, 2017). Esse salto tecnológico fez com que tais sistemas deixassem de ser meros repositórios de perguntas e respostas para se aproximarem cada vez mais da comunicação humana.

A história desses agentes remonta à década de 1950, com o Teste de Turing proposto por Turing (2009), que questionava se uma máquina poderia interagir de forma indistinguível de um ser humano. Embora na época não houvesse comprovação prática dessa hipótese, o teste se consolidou como um marco conceitual para o desenvolvimento da IA e dos *chatbots*. Inspirado por esse conceito, surgiu em 1966 o ELIZA, considerado o primeiro chatbot, criado por Weizenbaum (1966) para simular um terapeuta. Apesar de inovador, o sistema era limitado em manter diálogos longos e lidar com temas variados. Em 1972, foi desenvolvido o PARRY, projetado para simular um paciente com esquizofrenia paranoide (COLBY *et al.*, 1971), representando um avanço em relação ao ELIZA, mas ainda distante da sofisticação atual.

Nos anos seguintes, em 1995, surgiu o ALICE (WALLACE, 2009), um agente conversacional online que trouxe como inovação o uso da Artificial Intelligence Markup Language, permitindo interações mais complexas e flexíveis. Em 2006, a IBM apresentou o Watson (HIGH, 2012), que ganhou destaque ao vencer competidores humanos no quiz show *Jeopardy*, demonstrando um alto nível de compreensão de linguagem natural e aprendizado de máquina. Já na década de 2010, assistentes virtuais como a Siri (Apple) e o Google Assistant popularizaram o uso da voz como interface, expandindo as possibilidades de uso em dispositivos móveis (KEPUSKA; BOHOUTA, 2018).

Atualmente, modelos de LLM como o ChatGPT, da OpenAI, baseado na arquitetura

GPT, e o Gemini, do Google (anteriormente Bard), representam um salto qualitativo na capacidade dos *chatbots*. Esses sistemas conseguem interagir não apenas por texto, mas também por imagens e outros tipos de entrada, utilizando grandes volumes de dados para oferecer respostas coerentes e contextualmente adequadas em uma ampla variedade de situações (BENADDI *et al.*, 2024).

3.2.1 Plataformas de Desenvolvimento de *chatbots*

O avanço dos *chatbots* como ferramentas de interação homem-máquina está intimamente ligado ao desenvolvimento de plataformas especializadas que oferecem infraestrutura, bibliotecas e serviços para criação de assistentes virtuais inteligentes. Essas plataformas não apenas combinam recursos de Processamento de Linguagem Natural (PLN), aprendizado de máquina e integração com múltiplos canais de comunicação, mas também simplificam o trabalho dos desenvolvedores ao disponibilizar ferramentas pré-configuradas, modelos prontos e ambientes de fácil integração. Dessa forma, é possível construir sistemas capazes de compreender, interpretar e responder a solicitações de usuários de forma cada vez mais natural e eficiente (FØLSTAD *et al.*, 2021). Nas subseções a seguir, serão analisadas algumas das principais soluções disponíveis, como Dialogflow, IBM Watson Assistant, Pandorabots, Microsoft Bot Framework e Rasa, destacando suas características, vantagens e limitações.

3.2.1.1 Dialogflow

O Dialogflow, desenvolvido pelo Google, apresenta-se como uma das soluções mais populares devido à sua abordagem baseada em *intents* e *entities*, permitindo que desenvolvedores configurem exemplos de frases para treinar o modelo a reconhecer o objetivo das interações. Uma de suas principais funcionalidades é o uso de *contextos*, que viabilizam a manutenção de estados de conversa, permitindo diálogos encadeados e mais coerentes. Além disso, oferece integração nativa com múltiplos canais, como Google Assistant, Telegram, Facebook Messenger e plataformas web, o que amplia significativamente seu alcance. Entretanto, por ser um serviço hospedado em nuvem, apresenta limitações quanto ao processamento offline e pode impor restrições em aplicações que demandam maior controle sobre dados sensíveis (SABHARWAL; AGRAWAL, 2020).

3.2.1.2 IBM Watson

O IBM Watson Assistant destaca-se por oferecer recursos robustos de PLN e aprendizado contínuo, possibilitando a criação de diálogos dinâmicos e adaptativos com base no histórico e no contexto de interações anteriores. A plataforma dispõe de uma biblioteca de intenções e entidades pré-treinadas que aceleram o processo de desenvolvimento, além de ferramentas analíticas para monitorar métricas como taxa de resolução de consultas, tempo médio de resposta e engajamento dos usuários. Sua integração com diversos canais e aplicativos corporativos reforça seu papel em soluções empresariais de grande escala. Todavia, a complexidade de configuração para cenários específicos e a dependência de infraestrutura IBM podem ser desafios para equipes menos experientes (GLIOZZO *et al.*, 2013).

3.2.1.3 Pandorabots

O Pandorabots é uma plataforma que utiliza a linguagem AIML (*Artificial Intelligence Markup Language*) para definir regras e padrões de resposta, proporcionando um alto grau de controle sobre a estrutura das interações. Essa abordagem possibilita a reutilização de scripts AIML já existentes, o que facilita a migração de projetos antigos e a construção de sistemas baseados em conhecimento formalizado. Entretanto, essa flexibilidade vem acompanhada de uma curva de aprendizado mais acentuada, exigindo que o desenvolvedor compreenda em profundidade a sintaxe e a lógica de criação de padrões (RAJ; SUTEJA, 2019).

3.2.1.4 Microsoft Bot Framework

O Microsoft Bot *Framework* compõe-se de um conjunto abrangente de SDKs, APIs e conectores que permitem criar *chatbots* escaláveis e integrados ao ecossistema Microsoft. Uma de suas principais vantagens é a integração com o LUIS (*Language Understanding Intelligent Service*), que fornece capacidades avançadas de compreensão de linguagem. O *framework* é compatível com múltiplas linguagens de programação, incluindo C#, JavaScript e Python, e oferece conectores para Microsoft Teams, Skype, Slack, entre outros. Contudo, sua utilização plena pode exigir uma infraestrutura mais robusta e conhecimento prévio sobre os serviços de nuvem da Microsoft (WILLIAMS *et al.*, 2015).

3.2.1.5 Rasa

O Rasa configura-se como uma alternativa *open source* que combina flexibilidade e controle total sobre o fluxo conversacional. Composto por dois módulos principais, o Rasa NLU, responsável pela classificação de intenções e extração de entidades, e o Rasa Core, que gerencia o diálogo com base em aprendizado de máquina, a plataforma permite implantação local, garantindo maior privacidade e independência de serviços externos. Além disso, o Rasa é altamente extensível, permitindo a implementação de ações personalizadas em Python e integração com APIs externas. Apesar dessas vantagens, sua configuração inicial e manutenção podem demandar maior esforço técnico por parte das equipes de desenvolvimento (BOCKLISCH *et al.*, 2017).

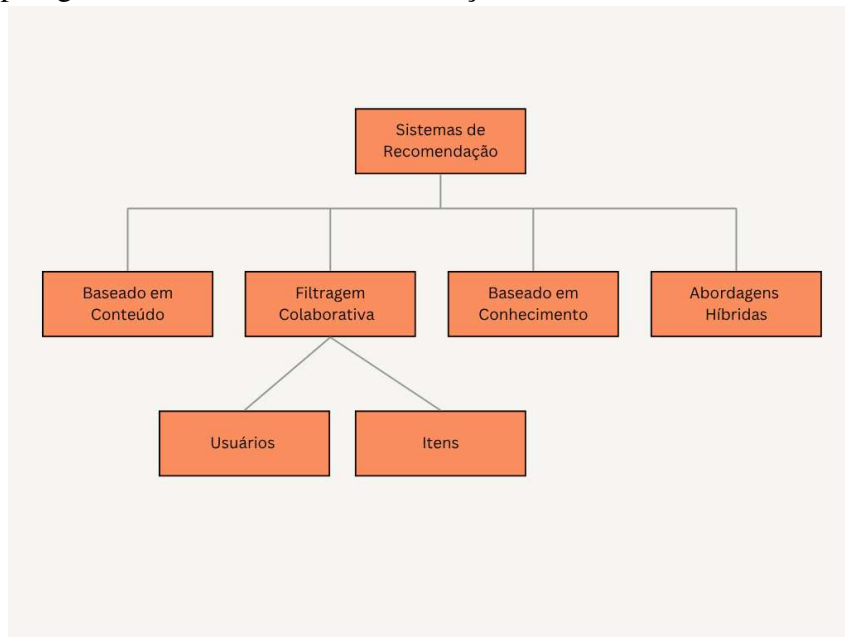
3.3 Sistemas de Recomendação

Os sistemas de recomendação têm se consolidado como componentes fundamentais em serviços digitais modernos, atuando como mediadores entre usuários e o vasto volume de informações disponíveis. Seu objetivo central é reduzir a sobrecarga cognitiva ao apresentar itens potencialmente relevantes para cada indivíduo, o que, por sua vez, aumenta a satisfação do usuário, o engajamento e a rentabilidade das plataformas que os utilizam (RICCI *et al.*, 2010).

De forma geral, a tarefa de recomendação consiste em prever a utilidade de um item para um usuário específico. Essa previsão pode se apoiar em diferentes fontes de informação, como avaliações explícitas, padrões de navegação, características intrínsecas dos itens ou mesmo informações contextuais adicionais (ADOMAVICIUS; TUZHILIN, 2005).

Conforme apresentado no Recommender Systems Handbook (RICCI *et al.*, 2010), os sistemas de recomendação são tradicionalmente classificados em diferentes categorias, cada uma baseada em abordagens distintas. A Figura 3 ilustra as tipologias mais populares, como a filtragem baseada em conteúdo, a filtragem colaborativa, os métodos baseados em conhecimento e as abordagens híbridas, amplamente aplicados em cenários reais. Cabe ressaltar, contudo, que as abordagens baseadas em contexto, que também serão apresentadas nesta seção, não aparecem de forma central nessa classificação, uma vez que se configuram como uma extensão relativamente mais recente e aplicada de maneira diferenciada.

Figura 3 – Tipologias de Sistemas de Recomendação



Fonte: Adaptado Agrawal (2019)

3.3.1 Filtragem Colaborativa

A filtragem colaborativa, também conhecida como filtragem social, é uma das abordagens mais populares e amplamente implementadas para sistemas de recomendação. Seu princípio fundamental é que as preferências de um usuário podem ser previstas com base nas avaliações de outros usuários com gostos similares. Diferentemente dos métodos baseados em conteúdo, a CF explora os padrões de avaliação de toda a comunidade para fazer suas previsões, sem depender de uma análise explícita das características dos itens (SCHAFER *et al.*, 2007).

Essa abordagem oferece vantagens significativas, como a capacidade de recomendar itens complexos e a habilidade de introduzir diversidade e serendipidade. Por exemplo, considere um usuário que avaliou positivamente filmes de ficção científica com narrativas complexas, como “Blade Runner” e “Matrix”. Um sistema baseado em conteúdo provavelmente recomendaria apenas outros filmes do mesmo gênero. Já a filtragem colaborativa pode identificar que outros usuários com gostos similares também avaliaram bem o filme “A Origem”, um thriller psicológico. A recomendação de “A Origem” seria um caso de serendipidade, uma descoberta inesperada e relevante, baseada no padrão de gosto compartilhado por narrativas complexas, e não apenas em etiquetas de gênero. Os métodos são classicamente divididos em duas grandes categorias: os baseados em vizinhança e os baseados em modelo (SCHAFER *et al.*, 2007).

Apesar de suas vantagens notáveis, a filtragem colaborativa enfrenta um desafio

fundamental conhecido como o problema do arranque a frio (*cold-start*). Essa limitação surge da própria natureza da abordagem, que depende de um volume mínimo de interações históricas para gerar recomendações. O problema se manifesta de duas formas: para um novo usuário, o sistema não tem base para encontrar “vizinhos” com gostos similares; e para um novo item, sem avaliações, o algoritmo não consegue recomendá-lo a ninguém. Este obstáculo é uma das principais considerações práticas na implementação de sistemas de recomendação e frequentemente exige o uso de estratégias híbridas para ser mitigado (PAZZANI; BILLSUS, 2007).

3.3.1.1 Métodos Baseados em Vizinhaça

As abordagens baseadas em vizinhaça, também conhecidas como métodos baseados em memória, são intuitivas e foram as primeiras a serem popularizadas. Elas operam diretamente sobre a matriz de interações usuário-item para encontrar "vizinhos", seja um grupo de usuários com gostos similares ou um conjunto de itens frequentemente avaliados de forma parecida. A predição para um item não avaliado é então calculada a partir de um subconjunto agregado de avaliações desses vizinhos mais próximos (ADOMAVICIUS; TUZHILIN, 2005). A popularidade desses métodos se deve à sua simplicidade, eficiência e à fácil interpretabilidade de suas recomendações.

Dentro desta categoria, existem duas implementações complementares: a centrada no usuário e a centrada no item.

- Filtragem Colaborativa Usuário-Usuário : Esta foi a abordagem original da CF. Ela recomenda itens para um usuário-alvo com base nas avaliações de usuários com gostos similares. A similaridade entre dois usuários é tipicamente calculada usando métricas como a Correlação de Pearson sobre o conjunto de itens que ambos avaliaram em comum. Uma vez que o bairro de vizinhos é formado, a predição da avaliação para um novo item é calculada como uma média ponderada das avaliações desses vizinhos, onde o peso de cada vizinho é proporcional à sua similaridade com o usuário-alvo. É crucial também normalizar as avaliações para mitigar os efeitos de diferentes escalas de avaliação entre os usuários (HERLOCKER *et al.*, 1999).
- Filtragem Colaborativa Item-Item : Esta técnica, por sua vez, prevê a avaliação de um usuário para um item com base nas avaliações que este mesmo usuário deu para itens similares. A similaridade entre dois itens é determinada a partir dos padrões de coavaliação de toda a base de usuários (SARWAR *et al.*, 2001). Esta abordagem ganhou grande popularidade

em aplicações comerciais, pois tende a ser mais escalável e estável. As relações entre itens mudam com menos frequência do que os gostos dos usuários, permitindo que o modelo de similaridade seja pré-calculado e usado de forma eficiente em tempo real (LINDEN *et al.*, 2003).

3.3.1.2 Métodos Baseados em Modelo

Em contraste com os métodos de vizinhança, as abordagens baseadas em modelo utilizam os dados de avaliação para aprender e treinar um modelo preditivo compacto. Em vez de memorizar toda a matriz de interações, esses métodos buscam descobrir fatores latentes, características implícitas e não observáveis, como dimensões de gênero ou estilo, que explicam as avaliações observadas. O modelo aprendido é então usado para fazer as recomendações, o que geralmente resulta em maior capacidade de generalização e melhor desempenho em matrizes de dados muito esparsas (ADOMAVICIUS; TUZHILIN, 2005).

A principal vantagem dos métodos baseados em modelo é que eles podem oferecer maior acurácia e lidar melhor com a esparsidade dos dados, um problema comum em sistemas de grande escala.

- **Fatoração de Matrizes:** Esta se tornou a técnica dominante em filtragem colaborativa, especialmente após sua popularização no Prêmio Netflix (KOREN *et al.*, 2009). A ideia central é decompor a grande e esparsa matriz de avaliações em duas matrizes de fatores latentes de menor dimensão: uma representando os usuários e suas afinidades por cada fator, e outra representando os itens e o quanto eles expressam esses mesmos fatores. A avaliação de um usuário para um item é então prevista pelo produto interno de seus respectivos vetores de fatores. Esta técnica é poderosa para capturar padrões complexos e sutis nos dados de preferência, e algoritmos como a SVD e suas variantes são frequentemente utilizados para este fim (KOREN *et al.*, 2009).
- **Outras Abordagens:** Além da fatoração de matrizes, outros algoritmos de aprendizado de máquina podem ser empregados. Redes neurais, por exemplo, podem ser usadas para aprender interações não-lineares complexas entre usuários e itens, potencialmente capturando nuances que modelos lineares como a fatoração de matrizes não conseguem. Da mesma forma, classificadores Bayesianos e modelos de clusterização também podem ser usados para agrupar usuários ou itens e, a partir daí, gerar previsões. Essas técnicas aumentam a robustez e a capacidade de generalização do sistema de recomendação (HE *et*

al., 2017).

3.3.2 *Filtragem Baseada em Conteúdo*

A filtragem baseada em conteúdo opera sob um princípio intuitivo: recomendar itens que sejam similares àqueles que um usuário demonstrou gostar no passado. Diferente da filtragem colaborativa, que depende dos padrões de uma comunidade, esta abordagem foca exclusivamente nas características dos itens e nas preferências de um único usuário (PAZZANI; BILLSUS, 2007).

O processo geralmente envolve duas etapas principais. Primeiramente, o sistema analisa os itens que o usuário avaliou positivamente para extrair suas características principais e construir um perfil de interesse do usuário. Por exemplo, no domínio de filmes, esse perfil pode conter informações sobre gêneros preferidos, diretores, atores ou palavras-chave do enredo. Em seguida, o sistema compara esse perfil com os atributos de outros itens no catálogo e recomenda aqueles que apresentam a maior similaridade (ADOMAVICIUS; TUZHILIN, 2005).

A filtragem baseada em conteúdo oferece vantagens importantes, como:

- **Independência do Usuário:** As recomendações para um usuário não dependem de outros, o que torna a abordagem útil em sistemas com poucos usuários ou dados esparsos.
- **Transparência:** As recomendações são facilmente explicáveis ("Recomendamos este filme porque ele é do mesmo gênero de ficção científica que você costuma assistir"), o que pode aumentar a confiança do usuário.
- **Tratamento de Novos Itens:** Um novo item pode ser recomendado imediatamente, desde que suas características sejam conhecidas, superando o problema de *cold-start* para itens.

Apesar de suas qualidades, a abordagem possui uma limitação fundamental conhecida como superespecialização. Como o sistema apenas recomenda itens com conteúdo similar aos já consumidos, ele raramente sugere itens de categorias inesperadas. Isso limita a capacidade de descoberta e a serendipidade, criando uma “bolha de filtro” para o usuário. Essa é uma das principais razões que motivam o desenvolvimento de sistemas híbridos, que buscam combinar as forças desta técnica com as da filtragem colaborativa (BURKE, 2002).

3.3.3 *Filtragem Baseada em Conhecimento*

A filtragem baseada em conhecimento fundamenta-se no uso explícito de conhecimento estruturado sobre o domínio do problema, bem como sobre as necessidades e restrições

do usuário, para gerar recomendações adequadas. Diferentemente das abordagens baseadas em conteúdo ou colaborativas, esse tipo de sistema não depende do histórico prévio de interações ou de avaliações passadas, mas sim de regras, modelos semânticos ou relações lógicas que descrevem como os itens atendem a determinados requisitos do usuário (RICCI *et al.*, 2010).

Nessa abordagem, o processo de recomendação ocorre a partir da correspondência entre as preferências explicitamente informadas pelo usuário e o conhecimento codificado no sistema. Esse conhecimento pode ser representado por meio de regras de inferência, ontologias, modelos de restrições ou redes semânticas, que descrevem tanto as características dos itens quanto as condições sob as quais eles são considerados adequados. Por exemplo, em um sistema de recomendação de imóveis, o usuário pode informar restrições como faixa de preço, número mínimo de quartos e localização desejada, e o sistema utiliza esse conjunto de critérios para identificar os imóveis que satisfazem tais condições (BURKE *et al.*, 2000).

A filtragem baseada em conhecimento apresenta vantagens relevantes, entre as quais destacam-se:

- **Independência de Histórico:** O sistema não requer dados prévios de interação, sendo especialmente adequado para domínios com baixa recorrência de uso ou em cenários de *cold-start* tanto para usuários quanto para itens.
- **Alta Interpretabilidade:** As recomendações podem ser facilmente explicadas com base nas regras ou restrições satisfeitas, aumentando a transparência e a confiança do usuário no sistema.
- **Adequação a Domínios Complexos:** É particularmente eficaz em contextos nos quais a escolha do item envolve múltiplas restrições explícitas e conhecimento especializado, como na recomendação de serviços financeiros, imóveis ou produtos técnicos.

Apesar de suas vantagens, essa abordagem apresenta limitações importantes. A principal delas é o custo associado à aquisição, modelagem e manutenção do conhecimento do domínio, que geralmente exige a participação de especialistas. Além disso, sistemas baseados em conhecimento tendem a ser menos adaptativos, uma vez que não exploram padrões emergentes a partir do comportamento coletivo dos usuários. Essas limitações motivam sua integração com outras técnicas, especialmente em sistemas híbridos, nos quais o conhecimento explícito do domínio é combinado com dados de interação e contexto, buscando maior flexibilidade e capacidade de personalização (BURKE, 2002).

3.3.4 *Sistemas Sensíveis ao Contexto*

Os sistemas sensíveis ao contexto ampliam o horizonte ao considerar variáveis adicionais relacionadas à situação em que ocorre a interação. Tempo, localização, dispositivo, clima ou companhia são exemplos de informações contextuais que podem alterar significativamente a relevância de uma recomendação (ADOMAVICIUS; TUZHILIN, 2015).

Por exemplo, um mesmo usuário pode preferir restaurantes rápidos durante o almoço em dias úteis, mas buscar opções mais sofisticadas à noite ou nos fins de semana. Da mesma forma, músicas recomendadas em uma manhã de trabalho podem diferir daquelas sugeridas em um momento de lazer. Incorporar tais dimensões aumenta a precisão e a relevância das recomendações.

O desafio, entretanto, reside na coleta e modelagem dessas informações. Dados contextuais são dinâmicos e heterogêneos, exigindo mecanismos de captura em tempo real e técnicas de aprendizado capazes de lidar com múltiplas variáveis. Além disso, surge a necessidade de explicar como o contexto influenciou determinada sugestão, reforçando a importância da interpretabilidade nesse tipo de sistema (VERBERT *et al.*, 2012).

A modelagem da informação contextual é tipicamente abordada por meio de três paradigmas principais, conforme formalizado na literatura (ADOMAVICIUS; TUZHILIN, 2015). O primeiro, a pré-filtragem contextual, consiste em selecionar apenas os dados relevantes para um determinado contexto *antes* de aplicar um algoritmo de recomendação tradicional. Por exemplo, para uma recomendação em um dia de semana, o sistema filtraria o histórico para incluir apenas avaliações feitas em dias de semana e, sobre esse subconjunto de dados, aplicaria um algoritmo de Filtragem Colaborativa. A segunda abordagem é a pós-filtragem contextual, na qual o sistema primeiro gera uma lista de recomendações e, em seguida, a filtra ou reordena com base no contexto atual do usuário. Por fim, a abordagem mais integrada e poderosa é a da modelagem contextual, na qual o contexto é incorporado diretamente ao modelo preditivo. Nesse caso, a função de predição não é mais bidimensional (usuário, item), mas sim multidimensional, incluindo uma ou mais dimensões contextuais.

3.3.4.1 *Contexto Conversacional*

Nos últimos anos, o conceito de contexto foi expandido para além do ambiente físico ou situacional, dando origem a uma nova geração de sistemas denominados *Sistemas de*

Recomendação Conversacionais

Nesses sistemas, o contexto é extraído dinamicamente a partir do próprio diálogo entre o usuário e o agente conversacional, em vez de depender exclusivamente de variáveis externas, como tempo ou localização (ADOMAVICIUS; TUZHILIN, 2015).

O contexto conversacional pode ser definido como o conjunto de informações derivadas da interação linguística e das intenções expressas durante o diálogo. Ele é composto por três dimensões principais:

- Histórico do diálogo: engloba o que foi dito anteriormente na conversa, incluindo preferências já mencionadas ou mapas visualizados.
- Intenções do usuário: representam o objetivo subjacente às mensagens como buscar um mapa, solicitar informações turísticas ou filtrar por categorias específicas.
- Entidades mencionadas: incluem os locais, categorias ou atributos explicitamente citados pelo usuário, extraídos por meio de técnicas de reconhecimento de entidades nomeadas.

3.3.5 Sistemas Híbridos

A diversidade de cenários e as limitações individuais de cada abordagem, como o problema de arranque a frio na filtragem colaborativa ou a superespecialização na filtragem baseada em conteúdo, levaram ao desenvolvimento de sistemas híbridos. Estes sistemas buscam combinar duas ou mais estratégias de recomendação para capitalizar suas fortalezas e, ao mesmo tempo, mitigar suas fraquezas. A forma como essa combinação é realizada pode seguir diferentes topologias de design, sendo as mais comuns a em cascata, a ponderada e a de comutação (BURKE, 2002). Na hibridização em cascata (*cascade*), uma técnica é utilizada para gerar um conjunto inicial de candidatos, que é então refinado por uma segunda técnica. Na hibridização ponderada (*weighted*), os escores de diferentes recomendadores são combinados em uma fórmula linear. Já na de comutação (*switching*), o sistema alterna entre as técnicas de acordo com um critério específico, como a disponibilidade de dados; por exemplo, usando um método baseado em conteúdo para um novo usuário e mudando para um colaborativo assim que ele acumula um número suficiente de avaliações.

Além de solucionar problemas práticos, os sistemas híbridos permitem um balanceamento mais fino entre os múltiplos objetivos de um sistema de recomendação. A abordagem em cascata, por exemplo, é particularmente útil para otimizar a performance em sistemas de grande escala. Enquanto um componente pode ser otimizado para maximizar a acurácia das predições,

outro pode ser projetado para aumentar a diversidade e a serendipidade, resultando em uma experiência de usuário mais rica e robusta. É por essa capacidade de gerenciar o *trade-off* entre métricas distintas que as soluções híbridas se tornaram o padrão de fato em aplicações comerciais de larga escala, como em plataformas de e-commerce e de streaming de mídia (RICCI *et al.*, 2010).

3.3.6 Fontes de Preferência

Na literatura de sistemas de recomendação, os dados que alimentam os modelos de personalização são geralmente categorizados em duas fontes principais: *feedback explícito* e *feedback implícito* (HU *et al.*, 2008).

Feedback Explícito refere-se à entrada direta, consciente e intencional do utilizador para expressar os seus interesses. É a forma mais inequívoca de preferência, classicamente representada por avaliações numéricas (como notas de 1 a 5) ou por indicações binárias, como *likes*. A principal vantagem deste método é a sua clareza na representação das preferências. No entanto, a sua maior desvantagem é a *data sparsity*. Na prática, a maioria dos utilizadores não avalia ativamente a maior parte dos itens disponíveis, pois isso exige um esforço cognitivo que nem todos estão dispostos a realizar (AGGARWAL *et al.*, 2016).

Feedback Implícito, por outro lado, consiste em sinais de preferência que não são fornecidos intencionalmente como uma avaliação, mas inferidos a partir da observação do comportamento natural do utilizador. Estes dados são recolhidos de forma passiva e automática, incluindo ações como histórico de compras, cliques, frequência de visitas ou o tempo de visualização de um item. A principal vantagem desse tipo de feedback é a sua abundância, pois é gerado em praticamente todas as interações do utilizador (NÚÑEZ-VALDÉZ *et al.*, 2012).

O desafio central do feedback implícito reside na sua *ambiguidade*. Em primeiro lugar, há uma ausência inerente de feedback negativo claro: a não interação com um item é ambígua, podendo significar desinteresse ou simplesmente falta de exposição. Em segundo lugar, mesmo os sinais “positivos” são frequentemente ruidosos; um clique, por exemplo, pode refletir interesse genuíno, curiosidade momentânea ou até um erro (HU *et al.*, 2008).

3.3.7 SVD Truncada para Fatoração de Matrizes

A SVD é uma técnica fundamental de álgebra linear para decomposição de matrizes, cuja finalidade é representar uma matriz qualquer como o produto de três matrizes que capturam,

de forma organizada, as principais direções de variação dos dados. Essa decomposição permite identificar fatores latentes subjacentes às relações originais da matriz, sendo amplamente utilizada em tarefas de redução de dimensionalidade, compressão de dados e análise de padrões (AGGARWAL *et al.*, 2016).


A SVD decompõe a matriz de interações R (m itens \times n usuários), que é tipicamente **esparsa**, no produto de três matrizes:

$$R = U\Sigma V^T \quad (3.1)$$

Essa decomposição é ilustrada na Figura 4. onde $p = \min(m, n)$:

- U : é a matriz ortogonal ($m \times p$) cujas colunas são os vetores singulares à esquerda (eixos principais dos itens).
- Σ : é uma matriz diagonal ($p \times p$) contendo os valores singulares em ordem decrescente, representando a importância de cada dimensão latente.
- V^T : é a matriz ortogonal ($p \times n$) cujas linhas são os vetores singulares à direita (eixos principais dos usuários).

Figura 4 – Ilustração da decomposição em valores singulares



Fonte: Adaptado de Yehoshua (2019)

3.3.7.1 Aplicações da SVD Truncada

Em sistemas de recomendação, a aplicação mais comum e eficaz é a SVD Truncada. Esta técnica consiste em reter apenas os k maiores valores singulares e seus vetores correspondentes, onde k é a dimensão do espaço latente desejado, sendo $k \ll p$ (WU *et al.*, 2025).


Ao reter apenas os k componentes mais importantes, obtém-se uma nova matriz

aproximada R_k :

$$R_k \approx U_k \Sigma_k V_k^T$$

A Figura 5 exemplifica graficamente o processo de truncagem da SVD, no qual apenas os k vetores e valores singulares mais relevantes são mantidos. O benefício da truncagem é duplo:

Figura 5 – Ilustração da SVD Truncada



Fonte: Adaptado de Yehoshua (2019)

1. Mitigação da esparsidade e redução de ruído: ao remover os valores singulares menos significativos, a SVD truncada elimina padrões insignificantes e reduz o impacto do ruído. Além disso, ela mitiga a esparsidade ao produzir uma reconstrução aproximada que preenche os zeros da matriz original com valores inferidos, resultando em representações mais densas e estáveis (KOREN *et al.*, 2009).
2. Controle de dimensionalidade: a projeção dos itens em um espaço de menor dimensão k concentra a informação nos principais fatores de variação, reduzindo o custo computacional e melhorando a capacidade preditiva em bases esparsas. Esse princípio é amplamente explorado em sistemas de recomendação baseados em fatoração matricial (KOREN *et al.*, 2009).

3.3.7.2 A Representação no Espaço Latente

A SVD Truncada projeta os itens em um novo espaço vetorial de baixa dimensão. A representação latente dos itens, $X_{itens} \in \mathbb{R}^{m \times k}$, é obtida ponderando os vetores singulares dos itens pelos valores singulares retidos:

$$X_{itens} = U_k \Sigma_k \tag{3.2}$$

Essa matriz X_{itens} fornece uma representação densa para cada item, onde cada dimensão do vetor corresponde a um fator latente que captura padrões coletivos de comportamento. Como consequência, a medição de similaridade, como a similaridade de cosseno, torna-se mais estável e significativa, uma vez que é calculada sobre vetores densos que refletem os fatores estruturais mais relevantes identificados pela decomposição truncada.

3.3.8 Avaliação de Sistemas de Recomendação

A avaliação de um sistema de recomendação é um processo multifacetado que visa medir a qualidade e a eficácia de suas sugestões. Tradicionalmente, as métricas de avaliação são divididas em duas categorias principais: métricas de acurácia, que focam na precisão das predições, e métricas que avaliam aspectos qualitativos da experiência do usuário, como diversidade e interpretabilidade.

3.3.8.1 Métricas de Acurácia

As métricas de acurácia quantificam o quão corretas são as recomendações do sistema. Elas se subdividem com base na tarefa principal do sistema: prever notas ou ranquear itens.

Para sistemas que preveem a nota que um usuário daria a um item (tarefa de regressão), as métricas mais consolidadas são:

- Erro Absoluto Médio (MAE): Calcula a média das diferenças absolutas entre os valores previstos (\hat{y}) e os reais (y), sendo facilmente interpretável por estar na mesma escala das notas.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

- Raiz do Erro Quadrático Médio (RMSE): Similar ao MAE, mas ao elevar os erros ao quadrado, penaliza de forma mais intensa predições muito distantes do valor real, sendo mais sensível a *outliers*.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

No entanto, como aponta a literatura, a precisão na predição da nota nem sempre se correlaciona com a satisfação do usuário. Em muitos cenários, o mais importante é a ordem em que os itens são apresentados (GUNAWARDANA; SHANI, 2009). Para essa tarefa de ran-

queamento (*Top-K ranking*), as métricas mais comuns incluem a Precisão@K, a Revocação@K (Recall@K), o Mean Average Precision (MAP) e o Normalized Discounted Cumulative Gain (NDCG). Tais métricas avaliam a qualidade e a ordem dos itens no topo da lista, refletindo melhor a experiência do usuário em plataformas de e-commerce ou streaming.

Apesar de sua ampla utilização, a eficácia dessas métricas de ranqueamento está intrinsecamente ligada a sistemas que operam com base em aprendizado supervisionado ou inferência dinâmica, nos quais as recomendações são personalizadas para cada usuário. Conforme apontado pela literatura (CORTES, 2023), a aplicação direta de métricas como NDCG e MAP torna-se inadequada para avaliar sistemas baseados em similaridade estática, onde a lista de recomendações para um item de referência é fixa e não se adapta. Para tais cenários, abordagens de avaliação alternativas, que medem a aderência das recomendações pré-calculadas ao comportamento real dos usuários, mostram-se mais apropriadas.

Além dessas métricas de ranking ordinal, uma outra abordagem comum, especialmente em cenários de feedback implícito, é tratar a tarefa como uma classificação binária de “acerto” (hit). A métrica central para isso é a Hit Rate @ K ou HR@K.

O HR@K é definido como a proporção de usuários para os quais o sistema conseguiu “acertar” pelo menos um item relevante que estava no conjunto de teste (HERLOCKER *et al.*, 2004). Esta métrica é ideal para medir se a recomendação foi *útil*, sem penalizar a ordem exata, sendo uma avaliação direta da capacidade do modelo de encontrar itens relevantes.

3.3.8.2 Métricas Além da Acurácia e a Interpretabilidade

Focar exclusivamente em acurácia pode levar a sistemas que geram recomendações óbvias e pouco úteis, diminuindo o engajamento a longo prazo. Por isso, a literatura também destaca a importância de avaliar dimensões qualitativas, conhecidas como métricas “além da acurácia” (*beyond-accuracy*). Entre elas, destacam-se:

- **Diversidade:** Mede o quão diferentes os itens recomendados são entre si.
- **Novidade:** Avalia a capacidade do sistema de recomendar itens que o usuário ainda não conhecia.
- **Serendipidade:** Mede a capacidade de fazer recomendações que são ao mesmo tempo novas e surpreendentemente úteis.

Nesse contexto, a avaliação de aspectos subjetivos como confiança, satisfação e percepção de utilidade pelo usuário também é crucial (TINTAREV; MASTHOFF, 2007). Um

fator determinante para melhorar essas percepções é a interpretabilidade (ou explicabilidade) do modelo. Ao fornecer explicações claras para suas sugestões, como por exemplo, "Recomendamos o item Y porque você se interessou por X", o sistema não apenas aumenta a confiança e a aceitação por parte do usuário, mas também fortalece a robustez da experiência de recomendação no mundo real (TINTAREV; MASTHOFF, 2011).

4 METODOLOGIA

Este trabalho é uma colaboração da UFC e a Prefeitura de Sobral, com o objetivo de apoiar os usuários do sistema Sobral em Mapas. Esse sistema utiliza tecnologia de GIS e dados geográficos abertos para exibir construções, rotas e outras convenções cartográficas, como linhas de ônibus, pontos de interesse e divisões administrativas da cidade. O *chatbot* NAVISOL, ainda em desenvolvimento, foi criado para facilitar a navegação e o acesso a essas informações de forma prática e acessível. Além de fornecer respostas e orientações diretas, o NAVISOL também atua como um sistema de recomendação, sugerindo rotas, locais e conteúdos relevantes com base nas perguntas ou preferências dos usuários.

Neste capítulo, são apresentados os métodos adotados para o desenvolvimento da solução. A metodologia inclui a análise das demandas dos usuários, o desenvolvimento de interações conversacionais simples, o tratamento e a integração dos dados geográficos, bem como a análise e a implementação de um sistema de recomendação híbrido, baseado em filtragem colaborativa item-a-item e enriquecido por informações oriundas do contexto conversacional, com o objetivo de melhorar a experiência de uso da plataforma Sobral em Mapas.

4.1 Análise das Demandas dos Usuários

A análise das demandas dos usuários foi conduzida de forma integrada ao desenvolvimento do sistema Sobral em Mapas e do *chatbot* NaVISOL. A identificação das necessidades ocorreu a partir de reuniões técnicas e levantamento de requisitos com as equipes Secretaria do Planejamento e Gestão (SEPLAG) e da Secretaria do Urbanismo e Meio Ambiente (SEUMA), considerando os objetivos centrais do projeto: facilitar o acesso a dados geográficos, como rotas de transporte público, edificações e divisões administrativas da cidade.

Além do mapeamento inicial de dúvidas e da definição de perfis de usuários potenciais, o sistema passou por testes com usuários reais durante o processo de desenvolvimento. Esses testes permitiram validar os fluxos de interação, identificar pontos de melhoria e ajustar tanto as funcionalidades do NaVISOL quanto a lógica do sistema de recomendação. O *feedback* obtido foi essencial para refinar a experiência do usuário e garantir que as respostas e sugestões oferecidas estivessem alinhadas às necessidades reais do público-alvo da plataforma.

A Figura 6 ilustra o fluxo adotado no desenvolvimento iterativo do *chatbot* NaVISOL, destacando as principais etapas do processo: levantamento de requisitos, definição de perfis de

usuários, primeiro ajuste no *chatbot*, aplicação de testes, coleta de *feedback* e ajustes progressivos no sistema. Para embasar essa etapa de validação, foi aplicado um formulário com moradores da cidade de Sobral, com o objetivo de identificar percepções, dificuldades de uso e sugestões de melhoria relacionadas à experiência com o *chatbot*.

Figura 6 – Fluxo de desenvolvimento do *chatbot*



Fonte: Elaborado pelo autor (2025).

Como ainda não se dispõe de uma estimativa precisa da quantidade total de usuários da plataforma, adotou-se o cálculo de amostra para população infinita. Foram utilizados os seguintes parâmetros: nível de confiança de 95%, erro amostral de 5% e proporção estimada de 13%, resultando em uma amostra mínima recomendada de 174 participantes. O cálculo foi realizado por meio da ferramenta disponibilizada pela Universidade de São Paulo (USP)¹.

As respostas obtidas foram analisadas quantitativamente e qualitativamente, permitindo validar os fluxos de interação e identificar pontos críticos. O *feedback* recebido foi utilizado para treinar o sistema de recomendação e ajustar os fluxos de conversa do *chatbot*, resultando em melhorias no conteúdo das mensagens e na estrutura das interações.

¹ <http://estatistica.bauru.usp.br/calculoamostral/ta_ic_proporcao.php>

4.2 Configuração do Ambiente

Antes da instalação das ferramentas principais, foi necessário garantir que a máquina utilizada possuísse o *Python*² e o gerenciador de pacotes *pip*³ devidamente instalados. O ambiente de desenvolvimento adotado para este trabalho foi um computador com sistema operacional Windows 11, processador Ryzen 7 5700U, 12 GB de memória RAM, e o Python 3.10. Para facilitar o controle das dependências e a criação de ambientes virtuais isolados, foi utilizado o *Anaconda Distribution*⁴, uma plataforma *open source* amplamente empregada em projetos científicos. A construção do sistema de recomendação foi baseada em técnicas de filtragem colaborativa baseada em vetores latentes. Para isso, foram utilizados módulos da biblioteca *Scikit-learn*⁵, como a função `cosine_similarity` para o cálculo da similaridade entre vetores, e a função SVD do módulo `numpy.linalg`⁶ para a decomposição de matrizes. Além disso, o framework *Rasa*⁷ foi instalado e configurado para possibilitar a implementação e o gerenciamento dos fluxos de conversa do *chatbot*, garantindo a integração entre o sistema de recomendação e a interface conversacional.

4.3 Desenvolvimento do *Chatbot*

O desenvolvimento do *chatbot* NaVISOL foi realizado utilizando o framework *Rasa*, uma plataforma de código aberto implementada em Python, amplamente utilizada em projetos de Processamento de Linguagem Natural (PLN). Essa base tecnológica permitiu o aproveitamento de ferramentas já consolidadas, facilitando a aplicação de técnicas de interpretação de linguagem aos dados de entrada dos usuários.

Um dos fatores determinantes para a adoção do *Rasa* foi o fato de ser uma solução gratuita e de código aberto, sem a necessidade de investimentos em licenças ou infraestrutura proprietária. Essa característica atende diretamente às necessidades de projetos públicos e colaborativos, como o Sobral em Mapas, permitindo o desenvolvimento de soluções robustas com custo reduzido.

Outro diferencial relevante foi a simplicidade de uso. O *Rasa* possui uma curva

² <<https://www.python.org/>>

³ <<https://pip.pypa.io/>>

⁴ <<https://www.anaconda.com/>>

⁵ <<https://scikit-learn.org/>>

⁶ <<https://numpy.org/>>

⁷ <<https://rasa.com/>>

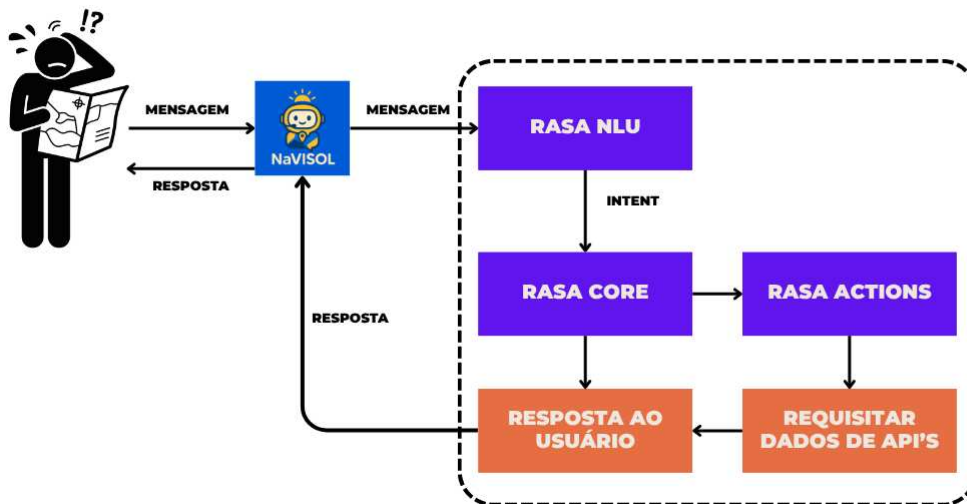
de aprendizado acessível, com sintaxe clara, documentação abrangente e exemplos práticos que aceleraram o desenvolvimento do NaVISOL. Essa facilidade contribuiu para que a equipe se concentrasse nas funcionalidades específicas do *chatbot*, sem a necessidade de enfrentar configurações excessivamente complexas ou restrições técnicas.

Outro aspecto fundamental foi a capacidade de integração do Rasa com sistemas externos por meio de sua API RESTful nativa. Esse recurso tornou possível a comunicação entre o *chatbot* e outros serviços do ecossistema Sobral em Mapas, como bases de dados geográficos, camadas GIS e módulos de recomendação.

4.3.1 Arquitetura de Funcionamento do Chatbot

A arquitetura do ciclo de funcionamento do *chatbot* NaVISOL, ilustrada na Figura 7, descreve o processo de interação entre o usuário e o agente conversacional por meio de um componente de chat integrado à aplicação web do sistema Sobral em Mapas. A comunicação ocorre por meio de requisições Hypertext Transfer Protocol (HTTP), utilizando o canal Application Programming Interface (API) fornecido pela Representational State Transfer (REST) do Rasa.

Figura 7 – Representação da Arquitetura do *Chatbot*



Fonte: Adaptado de (FGA-EPS-MDS, 2021)

4.3.2 Criação e Configuração do Chatbot

O ciclo tem início quando o usuário envia uma mensagem pela interface do chat. Essa mensagem é transmitida para o servidor do Rasa, onde o módulo Rasa Natural Language

Understanding (NLU) analisa o texto para identificar a intenção do usuário e entidades relevantes, como nomes de ruas, bairros ou pontos de interesse. Em seguida, o módulo Rasa Core processa essas informações e, com base nas políticas configuradas e no histórico de conversação, determina a ação mais adequada a ser executada.

Essa ação é interpretada pelo módulo Rasa Actions, que pode retornar uma resposta textual ou comandos específicos a serem utilizados pela aplicação web. Em alguns casos, essa resposta inclui dados que serão utilizados para interação visual com o mapa, como a marcação de pontos ou o traçado de rotas, funcionalidade que será detalhada em seção própria deste trabalho. Por fim, o conteúdo da resposta é enviado de volta à interface do chat, concluindo o ciclo de interação.

Com os pacotes necessários previamente instalados, o projeto do agente conversacional foi iniciado por meio do comando *rasa init*, que gerou a estrutura básica de diretórios e arquivos fundamentais. Essa estrutura inclui componentes como arquivos de treinamento de intenções e entidades, políticas de diálogo, ações personalizadas, respostas e configuração de domínio.

A configuração personalizada do *pipeline* de processamento e das políticas de decisão permitiu a criação de um agente conversacional com capacidade robusta de interpretação e tomada de decisão, alinhado ao domínio da aplicação proposta.

4.3.2.1 *Pipeline de Processamento de Linguagem Natural*

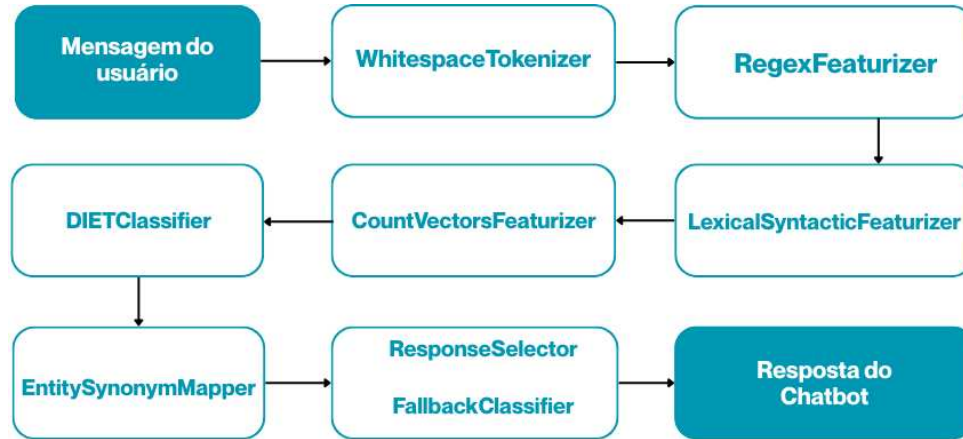
O *pipeline* de Processamento de Linguagem Natural (PLN) define as etapas pelas quais as mensagens dos usuários são processadas até serem compreendidas e interpretadas pelo sistema. Neste trabalho, adotou-se uma abordagem híbrida, que integra técnicas clássicas de pré-processamento textual com modelos baseados em aprendizado profundo, buscando maior robustez e precisão na interpretação das entradas.

De forma geral, o fluxo de processamento inicia-se com a segmentação e enriquecimento linguístico da mensagem do usuário, seguida pela transformação das informações textuais em representações vetoriais adequadas ao aprendizado de máquina. Essas representações são então utilizadas por um modelo central de aprendizado profundo, responsável pela interpretação semântica da entrada, cujos resultados passam por etapas adicionais de pós-processamento e tratamento de incertezas antes da geração da resposta final do chatbot.

A Figura 8 apresenta uma visão esquemática desse pipeline, evidenciando a sequência

de componentes responsáveis pelo processamento da linguagem natural, desde a entrada textual do usuário até a produção da resposta pelo agente conversacional.

Figura 8 – Fluxo do pipeline de Processamento de Linguagem Natural adotado no chatbot



Fonte: Elaborado pelo autor (2025).

A primeira etapa do *pipeline* consiste no *WhitespaceTokenizer*, responsável pela segmentação do texto com base em espaços em branco, gerando os *tokens*. Em seguida, aplica-se o *RegexFeaturizer*, que utiliza expressões regulares para identificar padrões relevantes nas mensagens, enquanto o *LexicalSyntacticFeaturizer* complementa essa análise ao extrair características sintáticas e léxicas do contexto em torno de cada *token*. Para a vetorização das entradas, são empregados dois componentes do tipo *CountVectorsFeaturizer*: o primeiro realiza a vetorização baseada na contagem de palavras (*bag-of-words*), e o segundo analisa *n-gramas* de caracteres, variando de 1 a 4, no modo *char_wb*, o que confere maior tolerância a erros de digitação e variações morfológicas.

O núcleo do *pipeline* é o *DIETClassifier*, um modelo multitarefa baseado em redes neurais profundas, responsável por realizar simultaneamente a classificação de intenções e a extração de entidades. Esse componente foi configurado para treinar durante 150 épocas, com a restrição de similaridade ativada (*constrain_similarities: true*), a fim de reduzir ambiguidades e evitar confusões entre intenções semanticamente próximas. Na sequência, o *EntitySynonymMapper* atua no mapeamento de sinônimos para formas padronizadas, promovendo maior consistência no reconhecimento das entidades, enquanto o *ResponseSelector* é utilizado em cenários com múltiplas respostas candidatas, como em bases de perguntas frequentes, sendo treinado ao longo de 100 épocas.

Por fim, o *FallbackClassifier* é acionado quando a confiança do modelo encontra-se abaixo de um limiar predefinido (*threshold: 0.3*) ou quando há ambiguidade entre intenções com

probabilidades semelhantes (*ambiguity_threshold: 0.1*). Esse mecanismo garante que, mesmo em situações de incerteza, o agente conversacional seja capaz de fornecer respostas coerentes e adequadas ao contexto, assegurando uma interação mais confiável e consistente com o usuário.

4.3.2.2 Políticas de Decisão do Diálogo

As políticas de decisão definem a forma como o agente seleciona suas ações ao longo da interação com o usuário, sendo responsáveis por controlar o fluxo do diálogo e garantir respostas coerentes ao contexto conversacional. Neste projeto, adotou-se uma combinação estratégica de quatro políticas principais: *MemoizationPolicy*, *RulePolicy*, *TEDPolicy* e *UnexpectTEDIntentPolicy*, de modo a equilibrar previsibilidade, flexibilidade e capacidade de generalização.

A *MemoizationPolicy* tem como função armazenar e reutilizar trajetórias de diálogo previamente observadas durante o treinamento, possibilitando respostas rápidas e consistentes em interações recorrentes ou altamente estruturadas. Complementarmente, a *RulePolicy* permite a definição de regras explícitas para o controle do fluxo conversacional, sendo especialmente eficaz em cenários de lógica determinística, como mensagens de saudação, encerramento e tratamento de situações de *fallback*.

A *TEDPolicy* (*Transformer Embedding Dialogue Policy*) é baseada em aprendizado profundo e utiliza representações contextuais para avaliar sequências de intenções e ações anteriores, a fim de prever o próximo passo do diálogo. Na configuração adotada, o modelo considera até cinco turnos anteriores (*max_history: 5*) e é treinado por 100 épocas. A ativação do parâmetro *constrain_similarities: true* contribui para uma maior separação entre as ações candidatas, reduzindo a probabilidade de decisões ambíguas durante a conversação. De forma complementar, a *UnexpectTEDIntentPolicy* foi incorporada com o objetivo de identificar e tratar intenções inesperadas, também considerando um histórico de cinco turnos e 100 épocas de treinamento. Essa política atua como um mecanismo adicional de robustez, prevenindo transições abruptas ou incoerentes no fluxo do diálogo.

A integração dessas políticas possibilita ao *chatbot* manter memória de contexto, responder adequadamente a padrões conhecidos e, ao mesmo tempo, adaptar-se a situações novas ou imprevistas, resultando em uma experiência conversacional mais fluida, estável e natural para o usuário.

4.3.3 Integração com o Sobral Mapas

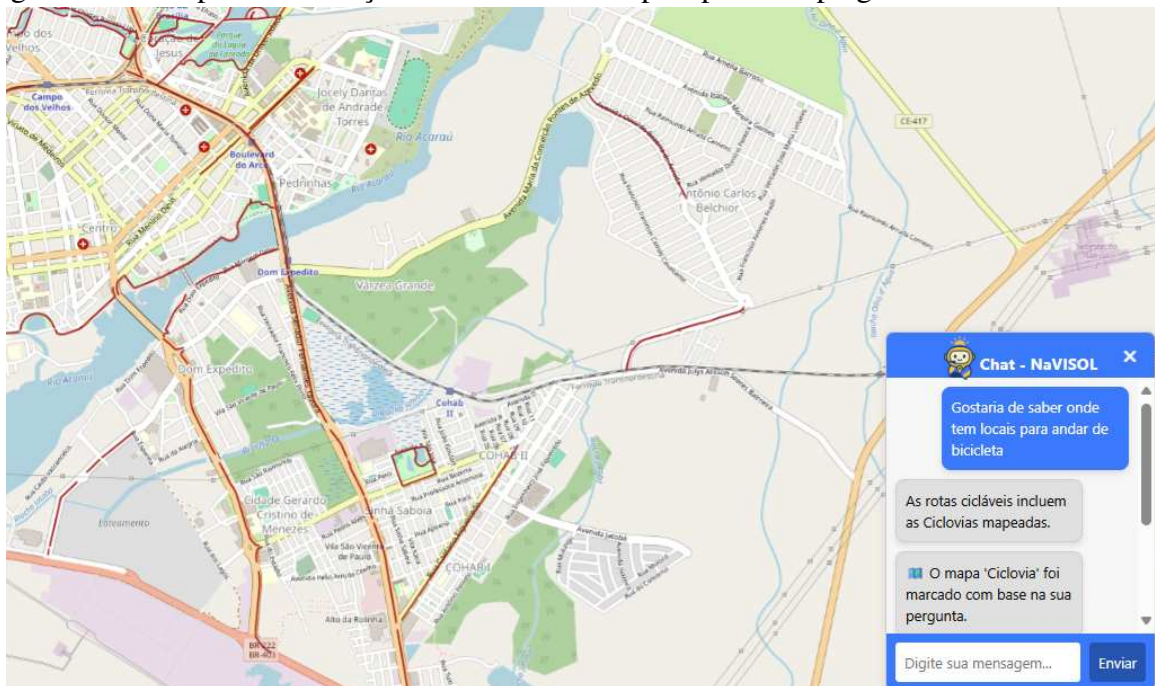
O Sobral Mapas é uma aplicação web que utiliza JavaScript para manipular visualmente os elementos do mapa. Nesse contexto, o *chatbot*, por meio do módulo `actions.py`, acionado pelo Rasa Core, é responsável por duas funções principais: marcar mapas e recomendar camadas.

Neste trabalho, as ações personalizadas não se limitam à geração de respostas textuais. Cada execução envia ao frontend um objeto JavaScript Object Notation (JSON) que agrega diferentes elementos de resposta, como o texto informando o nome ou a categoria do mapa identificado e a marcação visual correspondente no mapa.

Essa abordagem permite que o *frontend* ative automaticamente a camada apropriada com base nas entidades extraídas da pergunta e, ao mesmo tempo, incorpore ao JSON a recomendação gerada pelo modelo. Dessa forma, o agente conversacional e a interface do sistema funcionam de forma integrada, oferecendo interações ricas, contextuais e visualmente interativas, que conectam a linguagem natural à exploração geográfica assistida por recomendações.

A Figura 9 ilustra um exemplo dessa funcionalidade: ao perguntar sobre uma ciclovia específica, o sistema não apenas informa o resultado, mas também destaca automaticamente a camada correspondente no mapa.

Figura 9 – Exemplo de marcação automática no mapa a partir da pergunta do usuário



Fonte: Elaborado pelo autor (2025).

4.4 Implementação do Sistema de Recomendação

A abordagem adotada neste projeto é híbrida, combinando uma estratégia contextual, baseada no diálogo com o usuário, com a técnica de filtragem colaborativa item-a-item. Conforme ilustrado na Figura 10, essa arquitetura integra a compreensão semântica e interacional proporcionada pelo *chatbot* com um mecanismo de recomendação baseado em medidas de similaridade entre itens, extraídas a partir de padrões de comportamento coletivo. Essa integração permite que o sistema produza recomendações coerentes com o contexto da interação, ao mesmo tempo em que explora relações de afinidade entre mapas observadas no uso agregado do sistema.

Figura 10 – Fluxo do sistema de recomendação híbrido baseado em contexto e filtragem colaborativa



Fonte: Elaborado pelo autor (2025).

Nesta seção, são descritos os dois componentes fundamentais que compõem essa arquitetura híbrida. O componente colaborativo é responsável por identificar relações de similaridade entre mapas a partir das interações dos usuários, produzindo recomendações baseadas em uso coletivo. Já o componente contextual permite que o *chatbot* adapte as recomendações

conforme o conteúdo e a intenção expressa nas conversas, oferecendo respostas coerentes com o contexto atual do diálogo.

O componente colaborativo item-a-item foi popularizado por grandes aplicações comerciais, como a da Amazon.com (LINDEN *et al.*, 2003), e validado em diversas implementações. Neste projeto, ele se mostrou um método robusto e eficaz para o cenário proposto, especialmente por lidar bem com dados esparsos e restrições computacionais. A similaridade entre mapas (itens) é calculada com base na média do tempo relativo de visualização, utilizado aqui como uma forma de *feedback* implícito, ou seja, uma medida indireta do interesse do usuário. Diferentemente do *feedback* explícito, como avaliações ou notas, o *feedback* implícito é extraído do comportamento natural de navegação, tornando o processo de coleta automático e contínuo.

A partir desses dados, é construída uma matriz de similaridade item \times item que captura padrões de navegação e co-visualização entre usuários. Essa matriz permite identificar quais mapas tendem a ser acessados em sequência ou dentro de contextos semelhantes, gerando recomendações que refletem a afinidade entre conteúdos.

Uma das principais vantagens desta abordagem híbrida é sua capacidade de lidar bem com o problema de *cold start*, ou seja, situações em que há pouca ou nenhuma informação sobre novos usuários. O componente contextual garante que o *chatbot* consiga oferecer recomendações iniciais relevantes, como categorias de mapas, desde a primeira interação. Já o componente colaborativo requer apenas que o usuário visualize um único mapa para começar a sugerir conteúdos similares, dispensando um histórico extenso de uso.

Além disso, a matriz de similaridade colaborativa pode ser pré-computada e reutilizada, o que assegura respostas rápidas e alta escalabilidade mesmo em ambientes com recursos computacionais limitados. Enquanto isso, a lógica contextual é processada dinamicamente pelo agente conversacional, garantindo que as recomendações permaneçam coerentes com o diálogo em andamento e ajustadas ao contexto da interação.

4.4.1 Preparação dos Dados

Para possibilitar a geração de recomendações personalizadas, foi necessário estruturar os dados de interação dos usuários com a plataforma. A cada nova sessão, o endereço IP anonimizado do usuário (*ip_usuario*) é utilizado como identificador. Durante a navegação, os acessos aos mapas são registrados diretamente no *frontend* e enviados ao *backend*, onde são armazenados em uma tabela específica no banco de dados. Cada registro contém as seguintes

colunas:

- ip_usuario: endereço IP anonimizado do usuário;
- mapa: identificador da camada acessada;
- mapa_recomendado: nome do mapa sugerido como recomendação após o acesso ao mapa atual;
- tempo: tempo de visualização da camada;
- tempo_total: tempo total da sessão do usuário com o sistema;

Para a etapa de construção da matriz de interação e cálculo dos scores parciais, foram consideradas apenas as colunas ip_usuario, mapa, tempo e tempo_total, por serem diretamente relevantes à forma de modelagem adotada. Diferente de abordagens baseadas em cliques, que assumem eventos discretos e pontuais, este projeto adota uma lógica fundamentada no tempo de exposição.

A decisão por essa abordagem foi motivada por duas observações principais:

1. Em sistemas com interfaces interativas, os cliques são frequentemente empregados apenas como mecanismos operacionais de controle da visualização, como a ativação e desativação de camadas, não configurando, por si só, uma manifestação direta do interesse do usuário (UNRAU; KRAY, 2021).
2. O tempo de permanência é amplamente reconhecido na literatura como um indicador de interesse implícito mais robusto do que eventos de clique (CLAYPOOL *et al.*, 2001). Em interfaces baseadas em exploração visual, como mapas interativos, o tempo gasto pelo usuário em uma visualização é um preditor mais forte de engajamento e processamento cognitivo do que ações pontuais, que podem ser ambíguas (AGICHTEIN *et al.*, 2006).

Dessa forma, optou-se por utilizar o tempo relativo de visualização como *feedback* implícito contínuo. Para cada linha de ip foi calculado um *score* parcial, definido pela fração do tempo dedicado àquela camada em relação ao tempo total de navegação na sessão correspondente.

Após esse cálculo, as interações foram agrupadas por par *usuário* × *mapa*. Para cada usuário *u* e mapa *m*, foi computada a média dos scores parciais registrados, resultando na seguinte fórmula:

$$\text{score}_{u,m} = \frac{1}{n} \sum_{i=1}^n \text{score_parcial}_i; \quad (4.1)$$

onde:

- *n* é o número de interações do usuário *u* com o mapa *m*;

- $\text{score_parcial}_i = \frac{\text{tempo}_i}{\text{tempo_total}_i}$ representa a fração do tempo de visualização dedicado ao mapa na i -ésima interação.

O resultado é uma tabela no formato usuários \times mapas, com valores entre 0 e 1 que representam o grau médio de atenção dedicado por cada usuário a cada mapa. Um exemplo dessa estrutura é apresentado na Tabela 4.

Tabela 4 – Exemplo de Matriz de Interação (Formato Usuário-Mapa)

Usuário (IP)	Linha 1 do Transol	Linha 5 do Transol	Rede de Ciclovias
192.168.0.1	0,82	0,65	0,40
192.168.0.2	0,00	0,77	0,55
192.168.0.3	0,67	0,00	0,61

4.4.2 Treinamento

O treinamento do modelo foi conduzido com base nas interações reais dos usuários durante o uso da plataforma, servindo como fonte principal de dados para a construção do modelo de recomendação. A partir da tabela de scores médios descrita anteriormente (Tabela 4), reorganizada no formato mapa \times usuário conforme ilustrado na Tabela 5, foi construída uma matriz de interação $\mathbf{R} \in \mathbb{R}^{m \times n}$, onde m representa o número de mapas e n o número de usuários. Cada elemento $r_{i,j}$ da matriz representa o score médio atribuído pelo usuário j ao mapa i , com base no tempo relativo de visualização.

Tabela 5 – Exemplo de Matriz de Interação (Formato Usuário-Mapa transposta)

Mapa	192.168.0.1	192.168.0.2	192.168.0.3
Linha 1 do Transol	0,82	0,00	0,67
Linha 5 do Transol	0,65	0,77	0,00
Rede de Ciclovias	0,40	0,55	0,61

Para extrair apenas as componentes latentes mais relevantes presentes na matriz \mathbf{R} , aplicou-se inicialmente a Decomposição em Valores Singulares em sua forma completa, obtendo-se as matrizes \mathbf{U} , $\mathbf{\Sigma}$ e \mathbf{V}^\top .

A matriz \mathbf{U} contém os vetores singulares associados aos mapas, descrevendo como cada mapa se relaciona com as dimensões latentes extraídas a partir do comportamento coletivo dos usuários. A matriz $\mathbf{\Sigma}$ é uma matriz diagonal cujos valores singulares, ordenados de forma decrescente, indicam a importância relativa de cada dimensão latente na explicação das interações observadas. Já a matriz \mathbf{V}^\top contém os vetores singulares associados aos usuários, representando padrões latentes de navegação e de interesse no conjunto de mapas analisados.

Como os valores singulares presentes na matriz Σ estão ordenados de forma decrescente e expressam a contribuição de cada dimensão latente, torna-se possível reduzir a dimensionalidade do modelo por meio do truncamento da decomposição, preservando apenas as componentes mais informativas.

Em seguida, realizou-se o truncamento dessas matrizes, selecionando somente os cinco maiores valores singulares. A escolha de $k = 5$ foi definida após testes exploratórios, nos quais diferentes valores de k foram avaliados, e observou-se que cinco dimensões ofereciam um bom equilíbrio entre redução de ruído e preservação das estruturas latentes relevantes.

No código, o truncamento corresponde a:

$$\mathbf{U}_5 = \mathbf{U}[:, 1 : 5], \quad \Sigma_5 = \text{diag}(S_1, S_2, S_3, S_4, S_5), \quad \mathbf{V}_5^\top = \mathbf{V}^\top [1 : 5, :]$$

onde S_1, \dots, S_5 representam os cinco maiores valores singulares retornados pela função SVD.

A partir dessas matrizes reduzidas, construiu-se a representação latente dos mapas por meio da projeção:

$$\mathbf{X}_{\text{mapas}} = \mathbf{U}_5 \Sigma_5$$

Cada linha de $\mathbf{X}_{\text{mapas}}$ corresponde ao vetor latente de um mapa em um espaço de cinco dimensões, já ponderado pelos valores singulares preservados no truncamento. Essa matriz foi utilizada como base para o cálculo das similaridades entre os mapas, conforme exemplificado na Tabela 6.

Tabela 6 – Exemplo de vetores latentes dos mapas após aplicação do SVD (matriz $\mathbf{X}_{\text{mapas}}$)

Mapa	Dim 1	Dim 2	Dim 3	Dim 4	Dim 5.
Linha 1 do Transol	10,90	0,60	-5,23	2,05	3,10
Linha 5 do Transol	11,46	-5,55	-2,79	-2,06	-0,31
Rede de Ciclovias	10,27	0,35	1,24	-6,11	-0,12

Com a matriz $\mathbf{X}_{\text{mapas}}$, a similaridade entre dois mapas i e j é calculada com base na similaridade de cosseno, dada por:

$$\text{sim}(i, j) = \frac{\mathbf{x}_i \cdot \mathbf{x}_j}{\|\mathbf{x}_i\| \cdot \|\mathbf{x}_j\|} \quad (4.2)$$

onde \mathbf{x}_i e \mathbf{x}_j são os vetores-linha correspondentes aos mapas i e j na matriz $\mathbf{X}_{\text{mapas}}$.

Ao final de cada sessão de testes com usuários, foi gerada e armazenada uma matriz de similaridade contendo os valores de $\text{sim}(i, j)$ entre todos os pares de mapas. Essa matriz passou a ser utilizada como base para o sistema de recomendação, que, dado um mapa de interesse acessado pelo usuário, sugere automaticamente o mapa mais semelhante, com base no comportamento coletivo observado nas interações anteriores. A consulta a essa matriz é feita dinamicamente a cada nova solicitação de recomendação.

4.4.3 Avaliação baseada em incidência de uso

Diferentemente de sistemas de recomendação baseados em aprendizado supervisionado, nos quais modelos são treinados para prever preferências ou ordenar itens dinamicamente para cada usuário, o sistema proposto neste trabalho utiliza uma matriz de similaridade item-item fixa, pré-calculada a partir de medidas de similaridade (como cosseno ou decomposição SVD) entre diferentes mapas. Dessa forma, a recomendação é determinada exclusivamente pela similaridade entre itens previamente definida, sem adaptação ou personalização posterior.

Em sistemas baseados em predição, métricas como *Precision@K*, *Recall@K*, *F1@K*, *MAP* e *NDCG* são comumente empregadas, pois avaliam a capacidade do modelo de gerar rankings personalizados de itens relevantes. Contudo, conforme descrito na literatura (CORTES, 2023), essas métricas pressupõem a existência de um mecanismo de inferência adaptativa, o que não é o caso de sistemas puramente baseados em similaridade estática, como o adotado neste trabalho.

Para avaliar a efetividade da matriz de similaridade proposta, adotou-se uma abordagem fundamentada na taxa de coincidência entre recomendações fixas e interações reais. A lógica consiste em verificar, a partir de dados históricos de uso, se os mapas recomendados pelo sistema para determinado mapa base realmente foram acessados pelos usuários que previamente interagiram com esse mapa. Essa abordagem está alinhada à noção de *hit rate* em sistemas de caching por similaridade, nos quais a resposta recomendada é sempre a mesma para uma dada entrada (HERLOCKER *et al.*, 2004).

Os dados utilizados para essa avaliação foram organizados em uma tabela de logs, contendo campos essenciais como: *ip_usuario* (utilizado para delimitar a sessão de um usuário), *mapa* (o item-base que o usuário está visualizando) e *mapa_recomendado* (o item sugerido pelo sistema de similaridade estática para aquele mapa).

A partir dessa estrutura, a avaliação de eficácia foi calculada da seguinte forma: para cada instância em que um usuário acessou um mapa e uma recomendação foi registrada na coluna `mapa_recomendado`, o sistema verificou se, subsequentemente e dentro da mesma sessão (agrupada pelo `ip_usuario`), esse usuário de fato acessou o mapa que lhe foi recomendado.

A métrica final, denominada aqui de taxa de acerto por incidência, é calculada como a média dos acertos por recomendação. Para cada recomendação exibida i (de um total de $N_{\text{recomendações}}$), é atribuído um valor binário h_i (hit):

- $h_i = 1$ se o mapa recomendado foi acessado pelo usuário na mesma sessão, após a recomendação;
- $h_i = 0$ caso contrário (o mapa recomendado não foi acessado na sessão).

A taxa de acerto é então a soma desses acertos dividida pelo número total de recomendações, conforme a Equação 4.3:

$$\text{Taxa de Acerto} = \frac{\sum_{i=1}^{N_{\text{recomendações}}} h_i}{N_{\text{recomendações}}} \quad (4.3)$$

onde:

- $N_{\text{recomendações}}$ é o número total de recomendações exibidas em todas as sessões.
- h_i é a variável indicadora de acerto para a i -ésima recomendação.

Essa métrica fornece uma medida objetiva da eficácia prática da matriz de similaridade, refletindo diretamente a sua capacidade de antecipar, com base em similaridade, o comportamento real dos usuários sem o uso de técnicas preditivas ou aprendizado de máquina.

4.4.4 Integração das Recomendações no Sistema

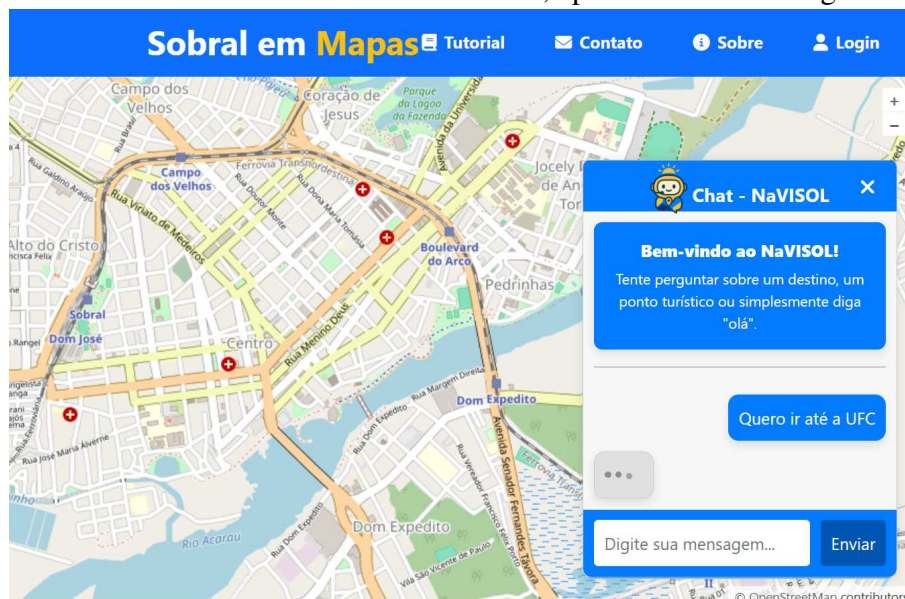
Após cada etapa de treinamento e refinamento do modelo, sua integração ao sistema conversacional era realizada por meio do componente de ações personalizadas do Rasa, conhecido como `actions.py`. Durante a execução do agente conversacional, quando o usuário realiza uma pergunta associada a um mapa ou categoria específica, o sistema dispara a função de recomendação implementada nesta ação. Essa função consulta a camada mencionada, identifica sua posição na matriz de similaridade pré-computada e retorna a camada geográfica mais similar com base na métrica de cosseno. O processo é representado pela seguinte lógica:

- Identificação da camada solicitada;

- Cálculo da similaridade entre a camada alvo e as demais, utilizando matriz de similaridade pré-computada;
- Seleção do mapa mais similar, excluindo o próprio mapa de origem;
- Recuperação do nome e categoria do mapa recomendado;
- Geração de mensagem personalizada enviada ao usuário;

Esse mecanismo permite que o *chatbot* não apenas responda à pergunta do usuário, como também ofereça uma recomendação contextual baseada no comportamento coletivo de navegação. A mensagem gerada, por exemplo, pode informar que “Usuários que acessaram esse mapa também visualizaram ‘Mapa X’, da categoria ‘Y’ ” assim como mostrados nas Figuras 11 e 12, agregando valor informacional e promovendo a exploração do sistema. Esse tipo de resposta reforça a utilidade do agente como mediador inteligente, tornando o processo de descoberta de informações mais dinâmico e guiado pelo contexto das interações. Além disso, a presença das recomendações diretamente no diálogo estimula a curiosidade e amplia o tempo de navegação do usuário na plataforma.

Figura 11 – Tela de boas-vindas do *chatbot* NAVISOL, apresentando uma sugestão de interação.

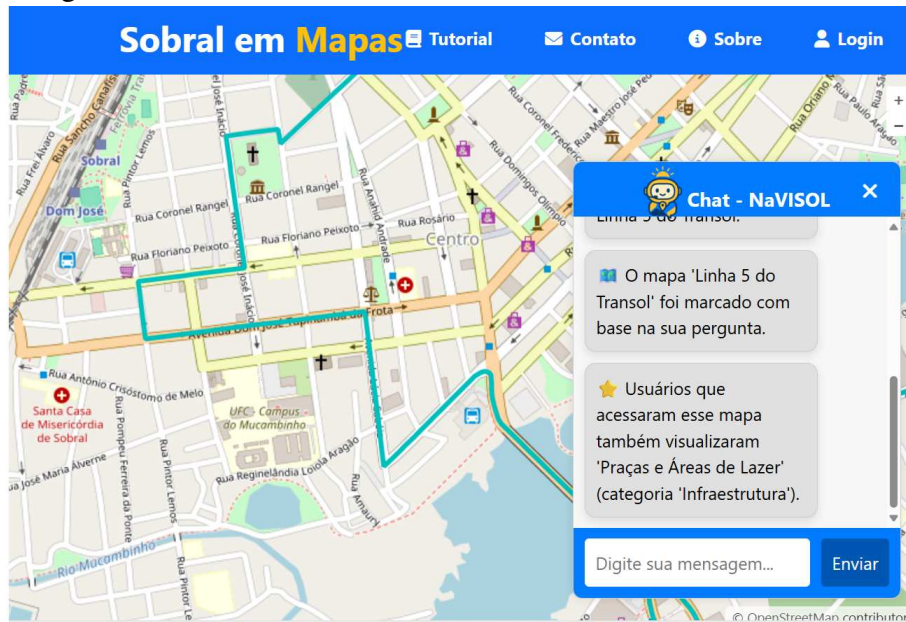


Fonte: Elaborado pelo autor (2025)

4.5 Metodologia de Avaliação da Experiência do Usuário

Para avaliar a qualidade da interação e o nível de satisfação dos usuários com o chatbot do portal Sobral em Mapas, foi elaborado um formulário de avaliação estruturado, apresentado no Apêndice 7. A fundamentação metodológica baseia-se em três fontes principais:

Figura 12 – Resposta do *chatbot* exibindo a rota no mapa e fornecendo uma recomendação de categorias relacionadas.



Fonte: Elaborado pelo autor (2025)

o framework ResQue, que define construtos de avaliação centrados no usuário para sistemas de recomendação (PU *et al.*, 2011); o instrumento Metrics of Success para avaliação de *chatbots* Møller *et al.* (2025); e o estudo Følstad e Brandtzaeg (2020), que analisa empiricamente fatores que influenciam a percepção de qualidade na interação com *chatbots*.

O formulário está dividido em três seções: (1) Perfil do Usuário, (2) Avaliação do *Chatbot* e (3) *Feedback* Aberto.

4.5.1 Perfil do Usuário

Esta seção busca compreender o perfil demográfico e o grau de familiaridade dos participantes com tecnologias de conversação. Antes das perguntas, o formulário apresenta uma breve definição de *chatbot*.

- Idade: utilizada para segmentação das análises. Følstad e Brandtzaeg (FØLSTAD; BRANDTZAEG, 2020) mostram que idade e outros dados demográficos influenciam como os usuários avaliam a experiência.
- Uso de aplicativos de mensagens instantâneas (Sim/Não): avalia a familiaridade com interfaces conversacionais, fator que influencia a fluidez da interação (FØLSTAD; BRANDTZAEG, 2020).
- Experiência prévia com chatbots (Sim/Não/Não tenho certeza): importante para estimar a

familiaridade tácita, que influencia avaliações subjetivas (MØLLER *et al.*, 2025).

- Nível de familiaridade com chatbots (escala 1–5): mede a autopercepção de conhecimento/uso, indicador relevante para entender diferenças de avaliação (MØLLER *et al.*, 2025; FØLSTAD; BRANDTZAEG, 2020).

4.5.2 Avaliação do Chatbot

Seção central do formulário, com perguntas em escala Likert de 5 pontos (1 = discordo totalmente; 5 = concordo totalmente). O uso dessa escala é coerente com recomendações psicométricas de Møller *et al.* (2025).

- A interação com o *chatbot* foi intuitiva: avalia a facilidade de uso e a fluidez da interação, construto presente em instrumentos de avaliação de *chatbots* (MØLLER *et al.*, 2025) e confirmado empiricamente por Følstad e Brandtzaeg (2020).
- O chatbot compreendeu suas perguntas corretamente: mede a acurácia percebida e a capacidade de entendimento, dimensão destacada em métricas de avaliação de chatbots (MØLLER *et al.*, 2025) e apontada como fator crítico para satisfação por Følstad e Brandtzaeg (2020).
- As recomendações fornecidas foram relevantes: avalia a utilidade percebida das respostas, construto presente em Pu *et al.* (2011).
- As recomendações ajudaram a encontrar novos lugares: corresponde ao construto novelty/discovery do ResQue, que avalia se o sistema auxilia na descoberta de itens não conhecidos anteriormente (PU *et al.*, 2011).

4.5.3 Feedback Aberto

Esta seção qualitativa capta aspectos não previstos pelas escalas, prática recomendada tanto por *frameworks* de recomendadores quanto por instrumentos de avaliação de *chatbots* (PU *et al.*, 2011; MØLLER *et al.*, 2025).

- O que você mais gostou na interação com o chatbot?
- Quais melhorias você sugeriria para o chatbot?

5 RESULTADOS

Esta seção apresenta os resultados obtidos a partir da avaliação do sistema desenvolvido, considerando duas fontes principais de análise: os dados de interação registrados automaticamente no banco de dados da plataforma durante o uso real do sistema e as respostas coletadas por meio de um formulário aplicado aos usuários que participaram dos testes do *chatbot*.

Os registros de uso permitem a análise quantitativa do funcionamento do sistema de recomendação, incluindo padrões de acesso às camadas de mapas e a verificação da efetividade das recomendações geradas. Já os dados provenientes do formulário fornecem uma avaliação qualitativa da experiência do usuário, abrangendo aspectos relacionados à usabilidade, compreensão das respostas do *chatbot*, relevância percebida das recomendações e auxílio na descoberta de novos locais.

5.1 Resultados Quantitativos do Sistema de Recomendação

Esta seção apresenta os resultados quantitativos obtidos a partir da avaliação do sistema de recomendação do NaVISOL. Embora o formulário de avaliação tenha sido respondido por 174 participantes, o monitoramento da plataforma identificou um total de 199 usuários únicos registrados no banco de dados. Para a análise quantitativa do desempenho do recomendador, foi considerada a totalidade desses 199 registros, uma vez que a avaliação se baseia no histórico de uso do sistema, independentemente da participação no formulário.

Os resultados estão organizados em duas frentes complementares: (i) a análise das matrizes de similaridade, comparando a matriz bruta de interações item–item com a representação latente obtida por meio da decomposição em valores singulares, a fim de observar padrões de associação entre mapas; e (ii) a avaliação do desempenho do sistema por meio do modelo de avaliação por incidência de uso que mensura a proporção de recomendações posteriormente seguidas pelos usuários.

Os 199 usuários foram organizados em quatro etapas cronológicas:

- **Etapa 1 (40 usuários):** Realizada em agosto de 2025, na Escola Estadual de Educação Profissional Lysia Pimentel, com a utilização dos computadores do laboratório de informática.
- **Etapa 2 (80 usuários):** Desenvolvida em setembro de 2025, durante a Semana da Ma-

temática na Universidade Estadual do Vale do Acaraú, por meio de uma exposição de cartazes.

- **Etapa 3 (120 usuários):** Ocorreu em outubro de 2025, por meio da divulgação do sistema em grupos de WhatsApp.
- **Etapa Final (199 usuários):** Realizada em novembro de 2025, durante as aulas de laboratório ministradas pelo professor Ialis, no campus da UFC em Sobral.

Cada etapa foi analisada quanto à evolução dos padrões observados nas matrizes de similaridade e ao desempenho medido pelo modelo de incidência de uso, apresentado ao final da seção.

5.1.1 Análise das Matrizes de Similaridade


5.1.1.1 Etapa 1: 40 Usuários

Na fase inicial do experimento, a decomposição em valores singulares não se limita a reforçar correlações previamente observáveis na matriz bruta, mas passa a revelar conexões latentes entre mapas que não apresentavam similaridade direta significativa.

Na Figura 13 o padrão predominante é de forte esparsidade, com a maioria dos pares apresentando valores próximos de zero. O principal agrupamento identificado ocorre entre as linhas do sistema Transol, especialmente entre `transol_linha_6`, `transol_linha_7` e `transol_linha_8`, cujas similaridades ultrapassam 0,7, indicando acesso simultâneo frequente a esses mapas. `Transol_linha_3` também apresenta associação com esse bloco, porém com intensidade um pouco menor, em torno de 0,6. Destaca-se ainda a correlação extremamente elevada entre `ciclovias_a` e `transol_linha_1`, indicando um padrão de navegação quase idêntico entre esses dois mapas. Além disso, observam-se correlações moderadas entre `escolas_municipal` e algumas linhas do Transol, especialmente com `transol_linha_3`, `transol_linha_7` e `transol_linha_8`. Fora desse conjunto, surgem apenas correlações pontuais, como a relação entre `acesso_a` e `praças_a`, bem como entre `praças_a` e `saúde_sobral`, sugerindo um padrão limitado de navegação associado a equipamentos urbanos básicos. A maioria dos outros mapas não forma grupos claros, mantendo similaridade mínima entre si.

Na Figura 14, após a aplicação do SVD truncado, nota-se uma reorganização expressiva das relações de similaridade. O agrupamento das linhas do Transol se amplia e se consolida, incluindo as linhas `transol_linha_4` e `transol_linha_5`, passando a estruturar praticamente todo o

Figura 13 – Matriz de Similaridade Bruta — Etapa 1 (40 usuários).




Fonte: Elaborado pelo autor (2025)

sub-bloco de mobilidade urbana. Esse comportamento indica que mapas de mobilidade passaram a ser reconhecidos como semanticamente próximos mesmo quando a relação direta observada na matriz bruta era limitada. Paralelamente, observa-se o fortalecimento das correlações entre mapas de infraestrutura urbana e serviços públicos, especialmente entre `acesso_a`, `pracas_a`, `saude_sobral` e `escolas_municipal`, cujos coeficientes atingem valores próximos de um, formando um segundo agrupamento bem definido. Também se evidenciam conexões transversais envolvendo o mapa `ensino_sobral_municipal`, que passa a apresentar similaridade moderada tanto com `escolas_municipal` quanto com diversas linhas do Transol, notadamente `transol_linha_7`, relações praticamente inexistentes na matriz sem SVD.

5.1.1.2 Etapa 2: 80 Usuários

Na Etapa 2 do experimento, a base é ampliada para 80 usuários, contemplando os 40 participantes iniciais somados a um novo conjunto de acessos. Esse aumento de volume reduz a esparsidade de forma pontual, sobretudo nos blocos associados à mobilidade urbana, ao mesmo

Figura 14 – Matriz de Similaridade com SVD — Etapa 1 (40 usuários).




Fonte: Elaborado pelo autor (2025)

tempo em que fornece ao espaço latente maior capacidade de identificar padrões transversais de navegação.

Na Figura 15, o bloco das linhas do Transol continua sendo o principal *cluster* observável, com destaque para as fortes correlações entre *transol_linha_3*, *transol_linha_7* e *transol_linha_8*, cujos coeficientes ultrapassam 0,80. Entretanto, fora do sistema Transol, as relações seguem majoritariamente pontuais. Destacam-se apenas associações localizadas, como entre *ciclovia_a* e *transol_linha_1*, que permanece com valor de 0,99, assim como entre *escolas_municipal* e as linhas *transol_linha_7* e *transol_linha_8*, sem a formação de agrupamentos temáticos amplos na matriz bruta.

Na Figura 16, após a aplicação do SVD truncado, ocorre uma reorganização ainda mais evidente das estruturas de similaridade. O *cluster* das linhas do Transol se amplia e se torna praticamente coeso, sendo fortemente estruturado pelas conexões entre *transol_linha_3*, *transol_linha_6*, *transol_linha_7* e *transol_linha_8*, com valores muito elevados. As linhas *transol_linha_4* e *transol_linha_5* apresentam integração mais limitada ao bloco principal, com

Figura 15 – Matriz de Similaridade Bruta — Etapa 2 (80 usuários).



Fonte: Elaborado pelo autor (2025)


correlações de menor intensidade quando comparadas ao núcleo do agrupamento. Esse conjunto passa a constituir o bloco mais dominante da matriz, indicando forte reconhecimento latente do perfil de navegação associado à mobilidade urbana.

Paralelamente, consolida-se de forma inequívoca um segundo grande agrupamento temático relacionado à infraestrutura urbana e aos serviços públicos. Os mapas *acesso_a*, *praças_a*, *saúde_sobral* e *escolas_municipal* apresentam correlações extremamente altas entre si, além de manterem fortes vínculos com parte do *cluster* de mobilidade, especialmente com *transol_linha_3*, *transol_linha_6*, *transol_linha_7* e *transol_linha_8*, cujos coeficientes também se aproximam de 1,0. Esse padrão indica a convergência entre interesses de usuários por conteúdos de transporte e por informações urbanas essenciais.

Em contrapartida, mapas como *paradas_linha_1* continuam apresentando comportamento isolado mesmo após a aplicação do SVD, mantendo baixos níveis de similaridade com

praticamente todos os demais itens. Isso sugere que seu padrão de uso permanece específico e pouco conectado aos fluxos de navegação predominantes, mesmo com a ampliação do volume de usuários.

Figura 16 – Matriz de Similaridade com SVD — Etapa 2 (80 usuários).




Fonte: Elaborado pelo autor (2025)

5.1.1.3 Etapa 3: 120 Usuários

Na Etapa 3 do experimento, a base é ampliada para 120 usuários, entretanto esse aumento de volume não se reflete em maior coesão na matriz de similaridade bruta, que permanece fortemente esparsa e fragmentada, inclusive com o enfraquecimento de correlações previamente observadas entre alguns mapas de mobilidade urbana. As associações diretas continuam restritas a poucos pares específicos, sem a formação de agrupamentos temáticos amplos. Nesse cenário, a aplicação do SVD assume papel fundamental para a identificação de estruturas latentes

de navegação, permitindo a consolidação de *clusters* mais estáveis e a evidência de conexões transversais entre conteúdos de mobilidade urbana, educação e infraestrutura pública que não se manifestam de forma direta na matriz original.


Figura 17 – Matriz de Similaridade Bruta — Etapa 3 (120 usuários).



Fonte: Elaborado pelo autor (2025)

Na Figura 17 observa-se a manutenção e até o aparente acirramento do padrão de esparsidade da matriz de similaridade bruta em relação às etapas anteriores, com predominância de valores próximos de zero ao longo de praticamente todo o plano. Mesmo o *cluster* das linhas do sistema Transol, que havia se mostrado mais coeso nas fases iniciais, passa a apresentar maior fragmentação, mantendo forte similaridade apenas entre transol_linha_7 e transol_linha_8, enquanto as demais conexões, especialmente envolvendo transol_linha_3, transol_linha_4 e transol_linha_6, tornam-se mais fracas e dispersas. A linha transol_linha_5 permanece periférica, sem integração consistente ao bloco principal. Fora do sistema Transol, as correlações continuam

Figura 18 – Matriz de Similaridade com SVD — Etapa 3 (120 usuários).



Fonte: Elaborado pelo autor (2025)

essencialmente pontuais, como nos casos entre praças_a e saúde_sobral e entre escolas_municipal e as linhas transol_linha_7 e transol_linha_8. A matriz bruta da Etapa 3, portanto, não evidencia a formação de agrupamentos temáticos amplos, apresentando inclusive um enfraquecimento das estruturas de similaridade previamente observadas.

Na Figura 18, após a aplicação do SVD truncado, observa-se uma reorganização muito mais pronunciada dos padrões de similaridade. O *cluster* das linhas do Transol passa a se estruturar a partir de um núcleo fortemente coeso formado por transol_linha_3, transol_linha_6, transol_linha_7 e transol_linha_8, com coeficientes frequentemente próximos de 1,0. As linhas transol_linha_4 e transol_linha_5 apresentam forte associação entre si, porém mantêm conexões mais fracas com o núcleo principal do agrupamento, configurando um sub-bloco secundário dentro do conjunto de mobilidade urbana. Paralelamente, o agrupamento formado por acesso_a, praças_a, saúde_sobral e escolas_municipal mostra-se ainda mais intenso do que na etapa

anterior, com correlações em geral superiores a 0,95, estabelecendo também vínculos elevados com o núcleo do *cluster* de mobilidade, especialmente com *transol_linha_6*, *transol_linha_7* e *transol_linha_8*.


5.1.1.4 Etapa Final: 199 Usuários

Na etapa final do experimento, com a amostra totalizando 199 usuários, a matriz de similaridade bruta permanece marcada por forte esparsidade e fragmentação, apresentando apenas correlações diretas pontuais, sem a formação de agrupamentos temáticos amplos, mesmo com o aumento do volume de acessos. Nesse contexto, a aplicação do SVD torna-se decisiva para a identificação de padrões estruturados de navegação, pois o espaço latente passa a evidenciar de forma consistente os principais *clusters* do sistema, especialmente aqueles associados à mobilidade urbana e à infraestrutura e serviços públicos, além de tornar visíveis conexões transversais entre temáticas que continuam pouco perceptíveis ou diluídas na matriz original.

Na Figura 19, observa-se que o agrupamento mais evidente continua sendo o das linhas do Transol, em especial entre *transol_linha_7* e *transol_linha_8*, cuja similaridade atinge aproximadamente 0,99, indicando forte acesso simultâneo. Algumas relações moderadas passam a surgir fora desse bloco, como entre *escolas_municipal* e *saúde_sobral*, bem como entre *praças_a* e *saúde_sobral*, além das associações entre *ensino_sobral_municipal* e *escolas_municipal*. No entanto, essas correlações permanecem pontuais e não configuram agrupamentos amplos ou estruturalmente coesos na matriz sem decomposição.

Na Figura 20, após a aplicação do SVD truncado, observa-se uma consolidação definitiva dos padrões de similaridade latente. O bloco associado às linhas do Transol forma um agrupamento denso, abrangendo *transol_linha_3*, *transol_linha_4*, *transol_linha_6*, *transol_linha_7* e *transol_linha_8*, com coeficientes geralmente superiores a 0,80 em praticamente todo o sub-bloco, destacando-se a ascensão de *transol_linha_4*, que nesta etapa passa a integrar de forma consistente o núcleo do *cluster* de mobilidade, diferentemente do comportamento mais periférico observado nas fases anteriores. Paralelamente, os mapas vinculados à infraestrutura urbana e aos serviços públicos, como *acesso_a*, *praças_a*, *saúde_sobral*, *escolas_municipal* e *ensino_sobral_municipal*, passam a apresentar correlações extremamente elevadas entre si, muitas delas próximas de 1,0, compondo um segundo grande *cluster* temático altamente coeso. Esse bloco também mantém fortes conexões com as linhas do Transol, especialmente com *transol_linha_6*, *transol_linha_7* e *transol_linha_8*, evidenciando a integração semântica entre pa-

Figura 19 – Matriz de Similaridade Bruta — Etapa final (199 usuários).



Fonte: Elaborado pelo autor (2025)

drões de mobilidade e de busca por serviços urbanos. Em contraste, mapas como paradas_linha_1 continuam a apresentar baixos níveis de similaridade tanto na matriz bruta quanto na matriz latente, permanecendo isolados dos principais agrupamentos identificados, o que indica um padrão de uso bastante específico e pouco relacionado aos fluxos principais de navegação, mesmo com o conjunto completo de usuários.


5.1.2 Avaliação por Incidência de Uso

A efetividade prática das recomendações foi avaliada por meio do modelo de avaliação por incidência de uso, que verifica a proporção de recomendações exibidas pelo sistema que resultaram no acesso posterior ao mapa sugerido.

Os resultados obtidos em cada etapa foram:

- Etapa 1: 16,67% (4 acessos em 24 recomendações);

Figura 20 – Matriz de Similaridade com SVD — Etapa final (199 usuários).



Fonte: Elaborado pelo autor (2025)

- Etapa 2: 14,29% (6 acessos em 42 recomendações);
- Etapa 3: 10,53% (6 acessos em 57 recomendações);
- Etapa Final: 10,66% (13 acessos em 122 recomendações).

Etapa	Taxa de Incidência
Etapa 1 (40)	16,67%
Etapa 2 (80)	14,29%
Etapa 3 (120)	10,53%
Etapa Final (199)	10,66%

Tabela 7 – Resumo da taxa de incidência por etapa.

Observa-se a tendência de estabilização da taxa de incidência nas fases finais do experimento, situando-se em torno de 10%. Em ambientes reais de recomendação e sistemas interativos, métricas baseadas em ação direta do usuário, como taxas de aceitação ou de

conversão, apresentam valores absolutos naturalmente baixos, em função do comportamento seletivo dos usuários frente a múltiplas opções. Nesse contexto, taxas na faixa de 5% a 10% são relatadas como compatíveis com níveis satisfatórios de desempenho em aplicações reais, conforme indicado por literatura consolidada de marketing digital e relatórios de benchmark de mercado (CHAFFEY; ELLIS-CHADWICK, 2019; WORDSTREAM, 2023). Dessa forma, o comportamento observado nesta avaliação reforça a consistência operacional do sistema à medida que a base de uso se amplia e os padrões coletivos de navegação se tornam mais estáveis.

5.2 Avaliação Qualitativa do Uso do *chatbot*

A avaliação qualitativa do sistema foi realizada por meio de um formulário aplicado aos usuários que interagiram com o NaVISOL, totalizando 174 respostas válidas. O objetivo dessa etapa foi complementar os resultados quantitativos, investigando a percepção dos participantes quanto à usabilidade, à clareza das respostas, à relevância das recomendações e ao potencial do sistema para apoiar a descoberta de novos locais. As afirmações do questionário foram avaliadas por meio de uma escala Likert de cinco pontos, variando de 1 (discordo totalmente) a 5 (concordo totalmente). Para fins de análise, as respostas 4 e 5 foram interpretadas como indicativas de concordância com a afirmação apresentada, enquanto as respostas 1 e 2 foram consideradas como discordância. A opção 3 foi interpretada como uma posição intermediária ou neutra, de modo que o somatório percentual das respostas 4 e 5 representa o nível de concordância dos participantes com cada afirmação avaliada.


5.2.1 Perfil dos Respondentes e Familiaridade com Tecnologias Digitais

Os dados indicam que praticamente todos os participantes utilizam aplicativos de mensagens instantâneas no cotidiano: aproximadamente 99% declararam usar ferramentas como WhatsApp, Telegram ou Messenger, enquanto apenas cerca de 1% afirmaram não utilizá-las como mostra. Esse cenário reforça que o público participante está habituado à interação em interfaces conversacionais, o que favorece a adoção de um *chatbot* como meio de acesso às informações do mapa.

Em relação à experiência prévia com *chatbots*, cerca de 88% dos respondentes acreditam já ter sido atendidos por esse tipo de sistema em outros contextos, enquanto uma parcela minoritária declarou não lembrar ou não ter certeza, e aproximadamente 3% afirmaram

nunca ter interagido com um *chatbot*. Quando questionados sobre o nível de familiaridade em uma escala de 1 a 5, a distribuição concentra-se nos níveis mais altos: pouco mais de um terço dos participantes atribuiu nota 5 e cerca de 29% atribuíram nota 4 como pode ser observado na Figura 21. Esse perfil de uso intensivo de aplicativos de mensagens e de familiaridade prévia com *chatbots* indica que os participantes possuem repertório para avaliar a solução proposta de forma crítica e contextualizada.

Figura 21 – Familiaridade com *chatbots*




Fonte: Elaborado pelo autor (2025)

5.2.2 Usabilidade e Facilidade de Uso

A usabilidade do *chatbot* foi avaliada por meio da afirmação “A interação com o *chatbot* foi intuitiva”. Os resultados apresentados na Figura 22 indicam que aproximadamente 63% dos participantes concordaram com a afirmação, ao atribuírem notas 4 ou 5, demonstrando que perceberam a interação como intuitiva. Cerca de 29% escolheram o valor intermediário 3, sugerindo neutralidade ou uma avaliação moderada, enquanto aproximadamente 8% discordaram da afirmação, ao atribuírem notas 1 ou 2, indicando experiências mais negativas.

Esses resultados sugerem que, para a maior parte dos usuários, a interface conversacional do sistema foi compreendida sem grande esforço, permitindo que a interação ocorresse de forma relativamente fluida. Ao mesmo tempo, a presença de uma parcela não desprezível de respostas intermediárias indica espaço para aprimoramentos, especialmente no que se refere à clareza das opções disponíveis e à orientação do usuário ao longo da conversa.


Figura 22 – Usabilidade do *chatbots*

Fonte: Elaborado pelo autor (2025)

5.2.3 *Compreensão das Respostas do Chatbot*

A clareza das respostas fornecidas pelo sistema foi analisada a partir da afirmação “O *chatbot* compreendeu suas perguntas corretamente”. Os resultados apresentaram uma distribuição mais equilibrada: cerca de 48% dos participantes concordaram com a afirmação, ao atribuírem notas 4 ou 5; aproximadamente 25% posicionaram-se no nível intermediário (nota 3); e em torno de 27% discordaram, ao indicarem notas 1 ou 2, conforme ilustrado na Figura 23.

Figura 23 – Compreensão das respostas



Fonte: Elaborado pelo autor (2025)


Esses números revelam que, embora quase metade dos usuários tenha percebido

que o *chatbot* interpretou adequadamente suas solicitações, há uma parcela significativa que encontrou dificuldades, seja por limitações na formulação das perguntas, seja por limitações do próprio modelo em lidar com certas variações de linguagem ou intenções. Essa percepção é coerente com algumas das sugestões abertas, nas quais os participantes mencionam a necessidade de melhorar a compreensão das perguntas e a precisão das respostas, especialmente em situações mais específicas.

5.2.4 Percepção sobre a Relevância das Recomendações

A relevância das sugestões apresentadas pelo sistema foi avaliada pela afirmação “As recomendações fornecidas foram relevantes”. Os resultados apresentados na Figura 24 indicam que aproximadamente 57% dos respondentes concordaram com a afirmação, ao atribuírem notas 4 ou 5. Por sua vez, cerca de 28% posicionaram-se no nível intermediário da escala (nota 3), enquanto em torno de 15% dos participantes discordaram da afirmação, ao atribuírem notas 1 ou 2.

Figura 24 – Relevância das Recomendações



Fonte: Elaborado pelo autor (2025)


Esse padrão indica que, para a maioria dos usuários, o conjunto de recomendações gerado pelo sistema foi percebido como pertinente em relação ao contexto da consulta. Ainda que exista uma fração de participantes que avaliou a relevância como moderada ou baixa, o predomínio de avaliações positivas sugere que o mecanismo de recomendação, fundamentado na análise de similaridade e na decomposição em valores singulares, foi capaz de entregar sugestões

alinhadas aos interesses de grande parte dos usuários. Quando comparados às taxas de incidência de uso em torno de 10%, esses resultados qualitativos indicam que a percepção de relevância não se traduz necessariamente em clique imediato em todas as recomendações, mas contribui para formar um repertório de opções consideradas úteis pelos participantes.

5.2.5 Apoio à Descoberta de Novos Locais

O potencial do sistema para apoiar a exploração do mapa foi examinado por meio da afirmação “As recomendações ajudaram a encontrar novos lugares”. Nesse item, conforme ilustrado na Figura 25, aproximadamente 60% dos participantes concordaram com a afirmação, ao atribuírem notas 4 ou 5. Cerca de 22% posicionaram-se no nível intermediário da escala (nota 3), enquanto em torno de 18% dos respondentes discordaram da afirmação, ao escolherem notas 1 ou 2.

Figura 25 – Descoberta de novos lugares



Fonte: Elaborado pelo autor (2025)

Esses resultados sugerem que o *chatbot* cumpriu papel relevante como ferramenta de descoberta, ampliando o acesso a camadas e locais que os usuários possivelmente não buscariam de forma direta. Essa evidência qualitativa complementa a análise das matrizes de similaridade, nas quais o espaço latente identificado pelo SVD revelou agrupamentos de mapas de mobilidade urbana e de infraestrutura e serviços públicos. Ao apresentar recomendações com base nessas estruturas latentes, o sistema parece ter favorecido a exposição dos usuários a conteúdos relacionados que não eram necessariamente óbvios, o que se reflete na percepção de

auxílio à descoberta de novos locais.

5.2.6 *Percepções Abertas e Sugestões de Melhoria*

As respostas abertas permitem aprofundar a compreensão sobre a experiência dos usuários com o *chatbot*, evidenciando tanto os aspectos mais valorizados quanto os principais pontos de melhoria percebidos durante o uso do sistema. Entre os elementos positivos mais recorrentes, destacam-se a rapidez das respostas, a praticidade de uso, a interface intuitiva e a utilidade das informações fornecidas sobre locais e rotas, especialmente no contexto do sistema de transporte coletivo. Diversos participantes relataram satisfação com a capacidade do *chatbot* de auxiliar na localização de pontos específicos no mapa e na orientação sobre opções de deslocamento urbano:

“Gostei da rapidez nas respostas e da facilidade de encontrar as linhas do transporte.”

“É bem intuitivo, e muito fácil de compreender e manipular. Acredito que seja um ponto crucial para explorar a cidade.”

“As sugestões que o chat dá facilitam bastante para encontrar lugares próximos, e as marcações no mapa ajudam bastante.”

“A marcação automática das sugestões de acordo com a pergunta deixa o sistema interativo e automatizado.”

“Ele responde bem às perguntas relacionadas à localização, além de indicar rotas e pontos para chegar até o destino.”

“O mapa é bastante detalhista e a interação com o chatbot facilita a busca de informações.”

Esses relatos reforçam a percepção predominante de que o sistema cumpre adequadamente seu papel como ferramenta de apoio à navegação exploratória, especialmente no contexto de conteúdos relacionados à mobilidade urbana e à busca por serviços e pontos de interesse.

Quanto às sugestões de aprimoramento, uma parcela expressiva dos respondentes declarou não identificar melhorias imediatas ou considerou o sistema satisfatório, o que reforça a aceitação geral da solução proposta. Entretanto, entre os participantes que apontaram limitações,

emergiram alguns eixos temáticos recorrentes. O primeiro refere-se à ampliação da cobertura informacional, com a inclusão de mais locais e pontos de interesse no mapa. Um segundo eixo destaca a necessidade de aperfeiçoar a compreensão das perguntas e a precisão das respostas, de modo a reduzir situações em que o *chatbot* não consegue interpretar corretamente a intenção do usuário ou acaba sugerindo conteúdos incorretos:

“Ele deveria melhorar na parte de compreensão com nossas perguntas.”

“Quando perguntei por uma escola específica, ele não reconheceu e não marcou nada no mapa.”

“O chatbot não conseguiu me responder corretamente quando pedi uma rota específica, recomendando linhas erradas.”

“Às vezes ele repete a mesma resposta ou parece não entender o contexto da pergunta.”

“Em perguntas mais informais ou com erros de escrita ele não compreende bem o que está sendo solicitado.”

Essas manifestações dialogam diretamente com os resultados quantitativos sobre percepção de compreensão do *chatbot*, nos quais uma parcela relevante dos usuários se manteve posicionada em níveis intermediários da escala de avaliação, indicando oportunidades concretas de melhoria na interpretação de linguagem natural.

Entre as sugestões diretamente relacionadas ao aperfeiçoamento da experiência de interação, chama atenção a proposta de inclusão de um indicador visual que evidencie o processamento das mensagens:

“Acredito que um indicador de que a mensagem está sendo processada possa ser uma boa implementação.”

Essa observação indica que, em determinados momentos da interação, os usuários não percebiam claramente se o sistema estava processando suas requisições, o que poderia gerar sensação de lentidão ou incerteza quanto ao funcionamento da aplicação. Como resposta direta a esse *feedback*, foi implementado no *chatbot* um indicador de digitação, representado pelos tradicionais três pontos (“...”), similares aos utilizados em aplicativos de mensagens instantâneas

como mostrado na Figura 11. Esse recurso passou a fornecer um retorno visual imediato ao usuário enquanto a resposta é elaborada pelo sistema, contribuindo para uma percepção mais clara do fluxo de interação e para o aumento da transparência no tempo de processamento das mensagens.

6 CONCLUSÕES E TRABALHOS FUTUROS

Este trabalho apresentou o desenvolvimento e a avaliação do NaVISOL, um agente conversacional integrado a um sistema de recomendação híbrido, proposto como camada de mediação inteligente para a plataforma Sobral em Mapas. A motivação central foi enfrentar as limitações de usabilidade dos sistemas GIS tradicionais e ampliar o potencial de descoberta de informações geográficas por parte da população, aproximando o cidadão dos dados públicos urbanos de forma acessível, intuitiva e proativa.

Os objetivos estabelecidos foram plenamente contemplados. Primeiramente, foram analisados os padrões de interação dos usuários com a plataforma, permitindo identificar barreiras relacionadas à navegação por menus complexos e à dificuldade de exploração autônoma de camadas temáticas. Em seguida, o *chatbot* foi projetado e implementado utilizando o *framework* Rasa, com integração direta ao ambiente web do Sobral em Mapas, possibilitando a manipulação do mapa por meio de linguagem natural e a apresentação dinâmica de rotas, pontos de interesse e categorias relacionadas.

No âmbito do sistema de recomendação, foi implementado um modelo híbrido que combina o contexto conversacional, o *feedback* implícito coletado a partir das interações dos usuários e a fatoração de matrizes via SVD como estratégia de mitigação da esparsidade de dados. A análise progressiva das matrizes de similaridade ao longo das quatro etapas experimentais demonstrou que o aumento do volume de interações promoveu maior densidade e organização do espaço latente, permitindo identificar relações semânticas relevantes entre as camadas do mapa. A aplicação da SVD mostrou-se especialmente útil para reduzir ruídos, reforçar padrões de associação e ampliar o alcance das recomendações, sobretudo nas etapas finais, quando a base de usuários se consolidou.

A avaliação quantitativa baseada na incidência de uso evidenciou que as recomendações apresentadas pelo NaVISOL resultaram, de forma consistente, no acesso posterior às camadas sugeridas, indicando efetividade prática do mecanismo de recomendação. Paralelamente, a avaliação qualitativa de usabilidade revelou altos índices de aceitação quanto à facilidade de uso, compreensão das respostas e percepção de relevância das recomendações, além de forte indicação de que o *chatbot* contribuiu para a descoberta de novos conteúdos geográficos que não seriam acessados apenas pela navegação convencional.

Dessa forma, os resultados confirmam que a integração entre interfaces conversacionais e sistemas de recomendação constitui uma abordagem promissora para plataformas de

GIS de participação pública, ao transformar a consulta reativa em uma experiência exploratória, fortalecendo a participação cidadã e o acesso consciente aos dados urbanos. O NaVISOL consolida-se, assim, como um artefato funcional e relevante tanto do ponto de vista tecnológico quanto social, demonstrando viabilidade para aplicação real em ambientes de gestão pública digital.

Apesar dos resultados positivos, o estudo apresentou limitações. A avaliação ocorreu em um período relativamente curto, não permitindo análises longitudinais de engajamento nem a observação da adaptação do modelo a mudanças comportamentais ao longo do tempo. Como trabalhos futuros, sugerem-se as seguintes direções:

- Ampliação da avaliação experimental para períodos mais longos e com maior diversidade de perfis de usuários.
- Incorporação de outros tipos de filtragem e de métricas adicionais para a avaliação de sistemas de recomendação, como NDCG, MAP e medidas de diversidade e novidade.
- Exploração de modelos mais avançados de representação semântica, incluindo *embeddings* contextuais espaciais e técnicas baseadas em LLM.
- Integração de novos sinais contextuais, como localização em tempo real, horário, eventos urbanos e perfis de mobilidade.
- Desenvolvimento de mecanismos de explicabilidade das recomendações, oferecendo ao usuário justificativas sobre as sugestões apresentadas.
- Avaliação do impacto do sistema sobre indicadores de engajamento cidadão e uso efetivo das informações públicas no processo de tomada de decisão.

REFERÊNCIAS

- ADOMAVICIUS, G.; TUZHILIN, A. Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions. **IEEE Transactions on Knowledge and Data Engineering**, v. 17, n. 6, p. 734–749, 2005.
- ADOMAVICIUS, G.; TUZHILIN, A. Context-aware recommender systems. In: _____. **Recommender Systems Handbook**. Boston, MA: Springer US, 2015. p. 191–226. ISBN 978-1-4899-7637-6. Disponível em: <https://doi.org/10.1007/978-1-4899-7637-6_6>.
- AGARWAL, J.; KUMAR, M.; SRIVASTAVA, A. K. Symptoms based disease diagnosis and treatment recommendation. In: IEEE. **2021 International Conference on Computational Performance Evaluation (ComPE)**. [S.l.], 2021. p. 162–167.
- AGGARWAL, C. C. *et al.* **Recommender systems**. [S.l.]: Springer, 2016. v. 1.
- AGICHTEIN, E.; BRILL, E.; DUMAIS, S. Improving web search ranking by incorporating user behavior information. In: **Proceedings of the 29th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval**. New York, NY, USA: Association for Computing Machinery, 2006. (SIGIR '06), p. 19–26. ISBN 1595933697. Disponível em: <<https://doi.org/10.1145/1148170.1148177>>.
- AGRAWAL, S. **Item-based collaborative filtering**. 2019. <https://medium.com/@Sumeet_Agrawal/item-based-collaborative-filtering-4e64f65ae6ea>. Accessed: 2025-10-01.
- AHAMED, B.; KAREEM, F.; MOHAMED, M. Y. N. Innovative approaches in predictive analysis and personalized online shopping recommendations with ai powered-chat. In: IEEE. **2025 International Conference for Artificial Intelligence, Applications, Innovation and Ethics (AI2E)**. [S.l.], 2025. p. 1–6.
- AMIRTHAVARSHINI, H.; CHAURASIYA, V. K.; KIRUBAKARAN, N.; SUNDARAMBAL, B. *et al.* A multilingual mental health support chatbot with regional language capabilities based on the amer model. In: IEEE. **2025 International Conference on Data Science, Agents & Artificial Intelligence (ICDSAAI)**. [S.l.], 2025. p. 1–6.
- ATZMANSTORFER, K.; BARTLING, M.; HALTOFOVÁ, B.; ZURITA-ARTHOS, L.; GRUBINGER-PREINER, J.; EITZINGER, A. Critical success factors of participatory community planning with geospatial digital participatory platforms. **ISPRS International Journal of Geo-Information**, v. 14, n. 4, 2025. ISSN 2220-9964. Disponível em: <<https://www.mdpi.com/2220-9964/14/4/153>>.
- BABU, T.; SHARMA, R. *et al.* Ai-powered chat agent: Revolutionizing online shopping. In: IEEE. **2024 2nd International Conference on Signal Processing, Communication, Power and Embedded System (SCOPE5)**. [S.l.], 2024. p. 1–5.
- BALAKRISHNAN, V.; LLOYD-YEMOH, E. Stemming and lemmatization: A comparison of retrieval performances. 2014.
- BANDARA, H.; RANATHUNGA, L. Ontology based restaurant recommendation approach. In: IEEE. **2023 3rd International Conference on Advanced Research in Computing (ICARC)**. [S.l.], 2023. p. 78–83.

- BARBOSA, J. L. N.; VIEIRA, J. P. A.; SANTOS, R.; JUNIOR, G. V. M.; MUNIZ, M. d. S.; MOURA, R. S. Introdução ao processamento de linguagem natural usando python. In: **III Escola Regional de Informática do Piauí**. [S.l.: s.n.], 2017. v. 1, p. 336–360.
- BARNS, S. Smart cities and urban data platforms: Designing interfaces for smart governance. **City, Culture and Society**, v. 12, p. 5–12, 2018. ISSN 1877-9166. Innovation and identity in next generation smart cities. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1877916617302047>>.
- BENADDI, L.; OUADDI, C.; JAKIMI, A.; OUCHAO, B. A systematic review of chatbots: Classification, development, and their impact on tourism. **IEEE Access**, IEEE, 2024.
- BOCHANOV, M. From reactive to proactive public management in the age of digital transformation. **Ars Administrandi** (), v. 16, p. 555–570, 01 2024.
- BOCKLISCH, T.; FAULKNER, J.; PAWLOWSKI, N.; NICHOL, A. Rasa: Open source language understanding and dialogue management. **arXiv preprint arXiv:1712.05181**, 2017.
- BURKE, R. Hybrid recommender systems: Survey and experiments. **User modeling and user-adapted interaction**, Springer, v. 12, n. 4, p. 331–370, 2002.
- BURKE, R. *et al.* Knowledge-based recommender systems. **Encyclopedia of library and information systems**, v. 69, n. Supplement 32, p. 175–186, 2000.
- CHAFFEY, D.; ELLIS-CHADWICK, F. **Digital marketing**. [S.l.]: Pearson uk, 2019.
- CLAYPOOL, M.; LE, P.; WASED, M.; BROWN, D. Implicit interest indicators. In: **Proceedings of the 6th International Conference on Intelligent User Interfaces**. New York, NY, USA: Association for Computing Machinery, 2001. (IUI '01), p. 33–40. ISBN 1581133251. Disponível em: <<https://doi.org/10.1145/359784.359836>>.
- COLBY, K. M.; WEBER, S.; HILF, F. D. Artificial paranoia. **Artificial intelligence**, Elsevier, v. 2, n. 1, p. 1–25, 1971.
- CORTES, D. **recometrics: Evaluation Metrics for Implicit-Feedback Recommender Systems**. [S.l.], 2023. R package version 0.1.6-3. Disponível em: <<https://CRAN.R-project.org/package=recometrics>>.
- DEVLIN, J.; CHANG, M.-W.; LEE, K.; TOUTANOVA, K. BERT: Pre-training of deep bidirectional transformers for language understanding. In: **Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers)**. Minneapolis, Minnesota: Association for Computational Linguistics, 2019. p. 4171–4186. Disponível em: <<https://aclanthology.org/N19-1423>>.
- DOMNICH, Y. The impact of product and process innovations on productivity: A review of empirical studies. **Foresight and sti governance**, v. 16, n. 3, p. 68–82, 2022.
- DU, H.; LI, H.; PENG, Q.; FU, L. User linguistic style awareness and interest-driven conversational recommender systems. In: IEEE. **2024 IEEE 4th International Conference on Digital Twins and Parallel Intelligence (DTPI)**. [S.l.], 2024. p. 215–220.
- FGA-EPS-MDS. **Documento de Arquitetura**. 2021. Acesso em 05 de julho de 2025. Disponível em: <<https://fga-eps-mds.github.io/2021.1-AlligaBot/2021/08/03/documento-de-arquitetura/>>.

FØLSTAD, A.; ARAUJO, T.; LAW, E. L.-C.; BRANDTZAEG, P. B.; PAPADOPOULOS, S.; REIS, L.; BAEZ, M.; LABAN, G.; MCALLISTER, P.; ISCHEN, C. *et al.* Future directions for chatbot research: an interdisciplinary research agenda. **Computing**, Springer, v. 103, n. 12, p. 2915–2942, 2021.

FØLSTAD, A.; BRANDTZAEG, P. B. Users' experiences with chatbots: findings from a questionnaire study. **Quality and User Experience**, Springer, v. 5, n. 1, p. 3, 2020.

GLIOZZO, A.; BIRAN, O.; PATWARDHAN, S.; MCKEOWN, K. Semantic technologies in ibm watson. In: **Proceedings of the Fourth Workshop on Teaching NLP and CL**. [S.l.: s.n.], 2013. p. 85–92.

GONSALVES, R.; PATIL, S.; PRADHAN, S.; PARSHIONIKAR, S. Medisense: An advanced health tech application using generative ai. In: **IEEE. 2024 International Conference on Artificial Intelligence and Quantum Computation-Based Sensor Application (ICAIQSA)**. [S.l.], 2024. p. 1–6.

GONZALEZ, M.; LIMA, V. L. S. Recuperação de informação e processamento da linguagem natural. In: **Anais do XXIII Congresso da Sociedade Brasileira de Computação**. [S.l.]: SBC, 2003. v. 3, p. 347–395.

GUNAWARDANA, A.; SHANI, G. A survey of accuracy evaluation metrics of recommendation tasks. **J. Mach. Learn. Res.**, JMLR.org, v. 10, p. 2935–2962, dez. 2009. ISSN 1532-4435.

HE, X.; LIAO, L.; ZHANG, H.; NIE, L.; HU, X.; CHUA, T.-S. Neural collaborative filtering. In: **Proceedings of the 26th International Conference on World Wide Web**. [S.l.: s.n.], 2017. p. 173–182.

HERLOCKER, J. L.; KONSTAN, J. A.; BORCHERS, A.; 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**. [S.l.: s.n.], 1999. p. 230–237.

HERLOCKER, J. L.; KONSTAN, J. A.; TERVEEN, L. G.; RIEDL, J. T. Evaluating collaborative filtering recommender systems. **ACM Trans. Inf. Syst.**, Association for Computing Machinery, New York, NY, USA, v. 22, n. 1, p. 5–53, jan. 2004. ISSN 1046-8188. Disponível em: <<https://doi.org/10.1145/963770.963772>>.

HIGH, R. The era of cognitive systems: An inside look at ibm watson and how it works. **IBM Corporation, Redbooks**, v. 1, p. 16, 2012.

HU, Y.; KOREN, Y.; VOLINSKY, C. Collaborative filtering for implicit feedback datasets. In: **IEEE. 2008 Eighth IEEE international conference on data mining**. [S.l.], 2008. p. 263–272.

Interaction Design Foundation. **What is Motivation in UX/UI Design?** 2016. Retrieved November 18, 2025. Disponível em: <<https://www.interaction-design.org/literature/topics/motivation>>.

JI, Y.; GAO, S.; NIE, Y.; MAJIĆ, I.; JANOWICZ, K. 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**, Taylor & Francis, p. 1–38, 2025.

KAISER, Z. A. Smart governance for smart cities and nations. **Journal of Economy and Technology**, v. 2, p. 216–234, 2024. ISSN 2949-9488. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2949948824000313>>.

KAJOSAARI, A. Scale dimensions in public participation gis: an overview for planning and research. **GeoJournal**, Springer, v. 89, n. 5, p. 197, 2024.

KEERTHANA, E.; REKHA, K. Multimodal conversational bot for multilingual personalized song recommendation. In: IEEE. **2024 International Conference on Recent Innovation in Smart and Sustainable Technology (ICRISST)**. [S.l.], 2024. p. 1–8.

KENTERIS, M.; GAVALAS, D.; MPITZIOPOULOS, A. A mobile tourism recommender system. In: IEEE. **The IEEE symposium on Computers and Communications**. [S.l.], 2010. p. 840–845.

KEPUSKA, V.; BOHOUTA, G. Next-generation of virtual personal assistants (microsoft cortana, apple siri, amazon alexa and google home). In: IEEE. **2018 IEEE 8th annual computing and communication workshop and conference (CCWC)**. [S.l.], 2018. p. 99–103.

KESELJ, V. Speech and language processing (second edition) daniel jurafsky and james h. martin (stanford university and university of colorado at boulder) pearson prentice hall, 2009, xxxi+988 pp; hardbound, isbn 978-0-13-187321-6, 115.00. **Computational Linguistics**, v. 35, p.463 – 466, 092009.

KOREN, Y.; BELL, R.; VOLINSKY, C. Matrix factorization techniques for recommender systems. **Computer**, IEEE, v. 42, n. 8, p. 30–37, 2009.

KOTKOV, D.; WANG, S.; VEIJALAINEN, J. Improving serendipity and accuracy in cross-domain recommender systems. In: . [S.l.: s.n.], 2017. p. 105–119. ISBN 978-3-319-66467-5.

KRATAITHONG, P.; BURANASING, W.; BURANARACH, M.; WUTTHITASARN, T.; MEEKLAI, P.; TUMSANGTHONG, P. Tourism chatbot framework: Enhancing visitor experience through graphrag and ai chatbot. In: IEEE. **2025 IEEE International Conference on Cybernetics and Innovations (ICCI)**. [S.l.], 2025. p. 1–6.

KRUPA, K.; AMBARA, G.; RAI, K.; CHOUDHURY, S. Emotion aware smart music recommender system using two level cnn. In: IEEE. **2020 Third International Conference on Smart Systems and Inventive Technology (ICSSIT)**. [S.l.], 2020. p. 1322–1327.

KUSHMITHA, S.; KATHRINE, J. W.; ABISHA, M. Natural language processing in geographic information systems. In: IEEE. **2025 3rd International Conference on Intelligent Data Communication Technologies and Internet of Things (IDCIoT)**. [S.l.], 2025. p. 295–300.

LIAO, L.; YANG, G. H.; SHAH, C. Proactive conversational agents. In: **Proceedings of the Sixteenth ACM International Conference on Web Search and Data Mining**. [S.l.: s.n.], 2023. p. 1244–1247.

LINDEN, G.; SMITH, B.; YORK, J. Amazon.com recommendations: Item-to-item collaborative filtering. **IEEE Internet Computing**, v. 7, n. 1, p. 76–80, 2003.

LIU, F.; CHEN, J.; YU, J.; ZHONG, R. Next point of interest (poi) recommendation system driven by user probabilistic preferences and temporal regularities. **Mathematics**, MDPI, v. 13, n. 8, p. 1232, 2025.

- LOOYESTYN, J.; KERNOT, J.; BOSHOFF, K.; RYAN, J.; EDNEY, S.; MAHER, C. Does gamification increase engagement with online programs? a systematic review. **PLOS ONE**, Public Library of Science, v. 12, n. 3, p. e0173403, 2017.
- LUO, H.; ZHOU, J.; BAO, Z.; LI, S.; CULPEPPER, J. S.; YING, H.; LIU, H.; XIONG, H. 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**. [S.l.: s.n.], 2020. p. 781–790.
- MAGAR, A.; ANAND, S.; MAHAJAN, T.; GUJAR, S.; WAVALE, K. Shopsavvy-empowering local commerce through online price comparison with ai integration for customers. In: IEEE. **2024 International Conference on Progressive Innovations in Intelligent Systems and Data Science (ICPIDS)**. [S.l.], 2024. p. 185–190.
- MANIKANDAN, B.; SELVARAJ, K.; ANJU, A.; NARENDRAN, M.; VENKAT, V. K. *et al.* Comprehensive mobile solution for personalized healthcare services using enhanced ai. In: IEEE. **2025 International Conference on Data Science and Business Systems (ICDSBS)**. [S.l.], 2025. p. 1–6.
- MANNING, C. D.; RAGHAVAN, P.; SCHÜTZE, H. **Introduction to Information Retrieval**. New York, NY, USA: Cambridge University Press, 2008.
- MANNING, C. D.; SCHÜTZE, H. **Foundations of Statistical Natural Language Processing**. Cambridge, MA, USA: MIT Press, 1999.
- MANSOURIAN, A.; OUCHEIKH, R. Chatgeoai: Enabling geospatial analysis for public through natural language, with large language models. **ISPRS International Journal of Geo-Information**, MDPI, v. 13, n. 10, p. 348, 2024.
- MATHEW, N.; CHOORAMUN, N.; SHARIF, M. S. Implementing a chatbot music recommender system based on user emotion. In: IEEE. **2023 International Conference on Innovation and Intelligence for Informatics, Computing, and Technologies (3ICT)**. [S.l.], 2023. p. 195–199.
- MEIJER, A.; BOLÍVAR, M. P. R. Governing the smart city: a review of the literature on smart urban governance. **International review of administrative sciences**, SAGE Publications Sage UK: London, England, v. 82, n. 2, p. 392–408, 2016.
- MIKOLOV, T.; CHEN, K.; CORRADO, G.; DEAN, J. Efficient estimation of word representations in vector space. **arXiv preprint arXiv:1301.3781**, 2013. Presented at Workshop at ICLR 2013.
- MISURACA, G.; NOORDT, C. V. **AI Watch - Artificial Intelligence in public services**. Luxembourg (Luxembourg), 2020.
- MOHER, D.; LIBERATI, A.; TETZLAFF, J.; ALTMAN, D. G. Preferred reporting items for systematic reviews and meta-analyses: the prisma statement. **Bmj**, British Medical Journal Publishing Group, v. 339, 2009.
- MOL, A. D.; ARUMUGAM, S.; RITHIKAA, B.; RITHIKA, R.; KAISAN, M.; PRAGASPATHY, S. Intelligent movie recommendation platform with ai-driven recommendation using machine learning with optimized power saving methods. In: IEEE. **2024 International Conference on**

- Distributed Systems, Computer Networks and Cybersecurity (ICDSCNC)**. [S.l.], 2024. p. 1–7.
- MØLLER, C. G.; ANG, K. E.; BONGIOVANNI, M. de L.; KHALID, M. S.; WU, J. Metrics of success: Evaluating user satisfaction in ai chatbots. In: **Proceedings of the 2024 8th International Conference on Advances in Artificial Intelligence**. New York, NY, USA: Association for Computing Machinery, 2025. (ICAAI '24), p. 168–173. ISBN 9798400718014. Disponível em: <<https://doi.org/10.1145/3704137.3704182>>.
- MURUGAN, H. S.; BHAVANA, K.; NIMITHA, S. S.; RASHMI, M. Trip craft: Personalized travel recommendation bot. In: IEEE. **2024 Second International Conference on Inventive Computing and Informatics (ICICI)**. [S.l.], 2024. p. 535–541.
- NÚÑEZ-VALDÉZ, E. R.; Cueva Lovelle, J. M.; Sanjuán Martínez, O.; GARCÍA-DÍAZ, V.; Ordoñez de Pablos, P.; Montenegro Marín, C. E. Implicit feedback techniques on recommender systems applied to electronic books. **Computers in Human Behavior**, v. 28, n. 4, p. 1186–1193, 2012. ISSN 0747-5632. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0747563212000325>>.
- OBIONWU, C. V.; TIWARI, T.; VALAPPIL, B. B. C.; RAIKAR, N.; WALIA, D. S.; ABBAS, S. L.; OKAFOR, C.; BRONESKE, D.; SAAKE, G. A domain specific students' assistance system for the provision of instructional feedback. In: IEEE. **2023 International Conference on Machine Learning and Applications (ICMLA)**. [S.l.], 2023. p. 2065–2070.
- OECD. **Governing with Artificial Intelligence: The State of Play and Way Forward in Core Government Functions**. Paris: OECD Publishing, 2025. Disponível em: <<https://doi.org/10.1787/795de142-en>>.
- PAVITHRA, S.; SWATHI, M.; SANJAY, R. *et al.* Guiding students to their future paths through website. In: IEEE. **2025 5th International Conference on Pervasive Computing and Social Networking (ICPCSN)**. [S.l.], 2025. p. 1929–1935.
- PAZZANI, M. J.; BILLSUS, D. Content-based recommendation systems. In: _____. **The Adaptive Web: Methods and Strategies of Web Personalization**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007. p. 325–341. ISBN 978-3-540-72079-9. Disponível em: <https://doi.org/10.1007/978-3-540-72079-9_10>.
- PENNINGTON, J.; SOCHER, R.; MANNING, C. D. Glove: Global vectors for word representation. In: **Proceedings of the 2014 conference on empirical methods in natural language processing (EMNLP)**. [S.l.: s.n.], 2014. p. 1532–1543.
- PEREIRA, A.; JUNIOR, J. Sistemas de recomendação baseados em dados espaciais: um mapeamento sistemático. **Revista Principia**, v. 62, 09 2025.
- PINHEIRO, P.; SIQUEIRA, L.; AMARIS, M. A four-step cascade methodology to classify mcnc codes using nlp techniques. In: **Anais do XIX Encontro Nacional de Inteligência Artificial e Computacional**. Porto Alegre, RS, Brasil: SBC, 2022. p. 389–400. ISSN 2763-9061. Disponível em: <<https://sol.sbc.org.br/index.php/eniac/article/view/22798>>.
- POLIGNANO, M.; NARDUCCI, F.; IOVINE, A.; MUSTO, C.; GEMMIS, M. D.; SEMERARO, G. *et al.* Healthassistantbot: A personal health assistant for the italian language. **IEEE ACCESS**, v. 8, p. 107479–107497, 2020.

PU, P.; CHEN, L.; HU, R. A user-centric evaluation framework for recommender systems. In: **Proceedings of the Fifth ACM Conference on Recommender Systems**. New York, NY, USA: Association for Computing Machinery, 2011. (RecSys '11), p. 157–164. ISBN 9781450306836. Disponível em: <<https://doi.org/10.1145/2043932.2043962>>.

RAHUL, S.; RAJVIGNESH, B.; RS, P. Survey shield: Safeguarding healthcare and diagnostic assistant. In: IEEE. **2025 International Conference on Machine Learning and Autonomous Systems (ICMLAS)**. [S.l.], 2025. p. 1160–1167.

RAJ, N. S.; SUTEJA, B. R. Implementasi aiml pada pandorabot untuk studi kasus fakultas teknologi informasi. **Jurnal STRATEGI-Jurnal Maranatha**, v. 1, n. 1, p. 13–22, 2019.

RIBEIRO, M. M.; SEGATTO, C. I. Inteligência artificial nas organizações públicas brasileiras: heterogeneidades e capacidades em tecnologia da informação. **Revista de Administração Pública**, SciELO Brasil, v. 59, n. 1, p. e2024–0066, 2025.

RICCI, F.; ROKACH, L.; SHAPIRA, B. Recommender systems handbook. In: _____. [S.l.: s.n.], 2010. v. 1-35, p. 1–35. ISBN 978-0-387-85819-7.

SABHARWAL, N.; AGRAWAL, A. **Cognitive virtual assistants using google dialogflow: develop complex cognitive bots using the Google dialogflow platform**. [S.l.]: Apress, 2020.

SAFITRI, S.; MANTORO, T.; BHAKTI, M. A. C.; WANDY, W. Cooking and food information chatbot system using gpt-3. In: IEEE. **2023 IEEE 9th International Conference on Computing, Engineering and Design (ICCED)**. [S.l.], 2023. p. 1–6.

SAKUDA, G.; LEON, J.; ROJAS, R. Mobile application for the intelligent management of small shops using the gpt-4 model. In: IEEE. **2024 IEEE 4th International Conference on Advanced Learning Technologies on Education & Research (ICALTER)**. [S.l.], 2024. p. 1–4.

SANJAYA, W.; CALVIN; MUHAMMAD, R.; MEILIANA; FAJAR, M. Systematic literature review on implementation of chatbots for commerce use. **Procedia Computer Science**, v. 227, p. 432–438, 2023. ISSN 1877-0509. 8th International Conference on Computer Science and Computational Intelligence (ICCSICI 2023). Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1877050923017106>>.

SARWAR, B.; KARYPIS, G.; KONSTAN, J.; RIEDL, J. Item-based collaborative filtering recommendation algorithms. In: **Proceedings of the 10th International Conference on World Wide Web**. [S.l.: s.n.], 2001. p. 285–295.

SASIKALA, T.; RAJ, J. J. D.; SWATHI, B.; DIDAGUR, D.; SHETTY, G. S. Smart ai chatbots for tailored nutrition and fitness guidance. In: IEEE. **2025 International Conference on Knowledge Engineering and Communication Systems (ICKECS)**. [S.l.], 2025. p. 1–6.

SCHAFER, J. B.; FRANKOWSKI, D.; HERLOCKER, J.; SEN, S. Collaborative filtering recommender systems. In: _____. **The Adaptive Web: Methods and Strategies of Web Personalization**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007. p. 291–324. ISBN 978-3-540-72079-9. Disponível em: <https://doi.org/10.1007/978-3-540-72079-9_9>.

SHAREEF, F.; AJITH, R.; KAUSHAL, P.; SENGUPTA, K. Retailgpt: A fine-tuned llm architecture for customer experience and sales optimization. In: IEEE. **2024 2nd International**

- Conference on Self Sustainable Artificial Intelligence Systems (ICSSAS)**. [S.l.], 2024. p. 1390–1394.
- SOLECHAH, N.; BAIZAL, Z.; IKHSAN, N. Sellybot: Conversational recommender system based on functional requirements. In: IEEE. **2022 International Conference on Data Science and Its Applications (ICoDSA)**. [S.l.], 2022. p. 315–319.
- SRINIVASAN, D.; UTHAYAKUMAR, A.; THIYAGALINGAM, P.; RAVINDRAN, S.; SILVA, H. D.; KASTHURURARTHNA, D. Escort-natural language processing based university students guidance system. In: IEEE. **2022 7th International Conference on Information Technology Research (ICITR)**. [S.l.], 2022. p. 1–6.
- SUCHONWANICH, N.; NUCHITPRASITICHAI, S.; VIRIYAPANT, K. Enhancing personalized financial advisory application with generative ai and chatbot: a usability study. In: IEEE. **2024 8th International Conference on Information Technology (InCIT)**. [S.l.], 2024. p. 97–102.
- SUKTHANKER, R.; PORIA, S.; CAMBRIA, E.; THIRUNAVUKARASU, R. Anaphora and coreference resolution: A review. **Information Fusion**, Elsevier, v. 59, p. 139–162, 2020.
- TEMARA, S.; SAMANTHAPUDI, S. V.; ROHELLA, P.; GUPTA, K. *et al.* Using ai and natural language processing to enhance consumer banking decision-making. In: IEEE. **2024 International Conference on E-mobility, Power Control and Smart Systems (ICEMPS)**. [S.l.], 2024. p. 1–6.
- THIRIMANNE, S.; RATHNAWEERA, W.; UNAIS, A.; SENADEERA, M.; ABEYWARDHANA, L. Chat-bot assisted recommendation platform for computers and repair services. In: IEEE. **2023 5th International Conference on Advancements in Computing (ICAC)**. [S.l.], 2023. p. 662–667.
- TINTAREV, N.; MASTHOFF, J. A survey of explanations in recommender systems. In: **2007 IEEE 23rd International Conference on Data Engineering Workshop**. [S.l.: s.n.], 2007. p. 801–810.
- TINTAREV, N.; MASTHOFF, J. Designing and evaluating explanations for recommender systems. In: _____. **Recommender Systems Handbook**. Boston, MA: Springer US, 2011. p. 479–510. ISBN 978-0-387-85820-3. Disponível em: <https://doi.org/10.1007/978-0-387-85820-3_15>.
- TSITSEKLIS, K.; STAVROPOULOU, G.; ZAFEIROPOULOS, A.; THANOU, A.; PAPAVALASSILOU, S. Recbot: Virtual museum navigation through a chatbot assistant and personalized recommendations. In: **Adjunct proceedings of the 31st ACM conference on user modeling, adaptation and personalization**. [S.l.: s.n.], 2023. p. 388–396.
- TURHAN, S.; BACAKSIZ, M. B. Recipe recommendation chatbot based on low fodmap dietary knowledge graph. In: IEEE. **2024 IEEE International Conference on Big Data (BigData)**. [S.l.], 2024. p. 6547–6555.
- TURING, A. M. **Computing machinery and intelligence**. [S.l.]: Springer, 2009.
- UNRAU, R.; KRAY, C. Mining map interaction semantics in web-based geographic information systems (webgis) for usability analysis. **AGILE: GIScience Series**, Copernicus Publications Göttingen, Germany, v. 2, p. 16, 2021.

UPADHYAY, A.; ROHAN, R.; KUMAR, J. P. *et al.* Virtual stylist: Outfit try-on and personalized fashion advice. In: IEEE. **2025 International Conference on Emerging Technologies in Computing and Communication (ETCC)**. [S.l.], 2025. p. 1–6.

VASWANI, A.; SHAZEER, N.; PARMAR, N.; USZKOREIT, J.; JONES, L.; GOMEZ, A. N.; KAISER, L. u.; POLOSUKHIN, I. Attention is all you need. In: GUYON, I.; LUXBURG, U. V.; BENGIO, S.; WALLACH, H.; FERGUS, R.; VISHWANATHAN, S.; GARNETT, R. (Ed.). **Advances in Neural Information Processing Systems**. Curran Associates, Inc., 2017. v. 30. Disponível em: <https://proceedings.neurips.cc/paper_files/paper/2017/file/3f5ee243547dee91fbd053c1c4a845aa-Paper.pdf>.

VERBERT, K.; MANOUSELIS, N.; OCHOA, X.; WOLPERS, M.; DRACHSLER, H.; BOSNIC, I.; DUVAL, E. Context-aware recommender systems for learning: A survey and future challenges. **IEEE Transactions on Learning Technologies**, v. 5, n. 4, p. 318–335, 2012.

WALLACE, R. S. **The anatomy of ALICE**. [S.l.]: Springer, 2009.

WEAKLIAM, J.; BERTOLOTTI, M.; WILSON, D. Implicit interaction profiling for recommending spatial content. In: . [S.l.: s.n.], 2005. p. 285–294.

WEIZENBAUM, J. Eliza—a computer program for the study of natural language communication between man and machine. **Communications of the ACM**, ACM New York, NY, USA, v. 9, n. 1, p. 36–45, 1966.

WILLIAMS, J. D.; KAMAL, E.; ASHOUR, M.; AMR, H.; MILLER, J.; ZWEIG, G. Fast and easy language understanding for dialog systems with microsoft language understanding intelligent service (luis). In: **Proceedings of the 16th Annual Meeting of the Special Interest Group on Discourse and Dialogue**. [S.l.: s.n.], 2015. p. 159–161.

WIRTZ, B. W.; WEYERER, J. C.; GEYER, C. Artificial intelligence and the public sector—applications and challenges. **International Journal of Public Administration**, Taylor & Francis, v. 42, n. 7, p. 596–615, 2019.

WORDSTREAM. **Google Ads Benchmarks by Industry**. 2023.

WU, W.; QI, Z.; TIAN, J.; WANG, B.; TANG, M.; LIU, X. An enhanced latent factor recommendation approach for sparse datasets of e-commerce platforms. **Systems**, MDPI, v. 13, n. 5, p. 372, 2025.

YEHOSHUA, R. **Singular Value Decomposition (SVD) Demystified**. 2019. Towards Data Science. Acesso em: 2025. Disponível em: <<https://towardsdatascience.com/singular-value-decomposition-svd-demystified-57fc44b802a0/>>.

ZHAO, D.; PETROV, A.; IVANOV, D.; VOLKOV, S.; SMITH, J.; WANG, J. Exploring geographic information systems (gis) for smart city analytics. 02 2025.

7 QUESTIONÁRIO APLICADO AOS PARTICIPANTES

Avaliação de chatbot Sobral em Mapas

Este formulário tem como objetivo avaliar a experiência dos usuários com o **chatbot do site Sobral Maps**:

<https://spacesolutions.alphi.media/sobralmapas/public/>

Queremos entender como foi sua interação com o chatbot, identificar pontos fortes e oportunidades de melhoria. Suas respostas são muito importantes para aprimorar o atendimento automatizado e tornar a navegação mais eficiente e agradável para todos os usuários.

** Indica uma pergunta obrigatória*

Perfil do Usuário

Um **chatbot** é um programa que simula uma conversa com uma pessoa, respondendo perguntas e oferecendo suporte de forma automática. Ele é utilizado em sites, aplicativos e plataformas de mensagens, como o WhatsApp, para facilitar o atendimento. Um exemplo é o chatbot da Enel, que auxilia com dúvidas sobre contas de luz.

A seguir, responda algumas perguntas para podermos entender melhor seu perfil e sua experiência prévia com esse tipo de tecnologia.

1. Qual sua Idade? *

2. Você utiliza aplicativos de mensagens instantâneas (como WhatsApp, Telegram, Messenger)? *

Marcar apenas uma oval.

Sim

Não

3. Você acredita que já foi atendido(a) por um chatbot antes? *

Marcar apenas uma oval.

- Sim
 Não
 Não tenho certeza

4. Qual seu nível de familiaridade com chatbots? *

Marcar apenas uma oval.

1 2 3 4 5

Nen Muita familiaridade

Avaliação do Chatbot

Nesta seção, queremos saber como foi sua experiência com o **chatbot do site Sobral Maps**. As perguntas a seguir avaliam aspectos como clareza das respostas, facilidade de uso e utilidade das informações recebidas.

Você deverá utilizar uma **escala de 1 a 5**, onde:

1 = Discordo totalmente

5 = Concordo totalmente

Com base na sua interação, marque a opção que melhor representa sua opinião para cada item.

5. A interação com o chatbot foi intuitiva. *

Marcar apenas uma oval.

1 2 3 4 5

Disc Concordo totalmente

6. O chatbot compreendeu suas perguntas corretamente. *

Marcar apenas uma oval.

1 2 3 4 5

Disc Concordo totalmente

7. As recomendações fornecidas foram relevantes. *

Marcar apenas uma oval.

1 2 3 4 5

Disc Concordo totalmente

8. As recomendações ajudaram a encontrar novos lugares. *

Marcar apenas uma oval.

1 2 3 4 5

Disc Concordo totalmente

Feedback Aberto

Nesta seção, você pode compartilhar livremente suas impressões sobre o chatbot. Suas respostas nos ajudam a entender o que funcionou bem e o que pode ser melhorado. Fique à vontade para destacar pontos positivos e sugerir melhorias.

9. O que você mais gostou na interação com o chatbot?

10. Quais melhorias você sugeriria para o chatbot? *

100

Este conteúdo não foi criado nem aprovado pelo Google.

Google Formulários