



UNIVERSIDADE FEDERAL RURAL DO SEMI-ÁRIDO
UNIVERSIDADE DO ESTADO DO RIO GRANDE DO NORTE
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO



FELIPE GABRIEL QUEIROZ REGO

**RECOMENDAÇÃO PERSONALIZADA DE CONTEÚDO PARA SUPORTE À
APRENDIZAGEM INFORMAL NO CONTEXTO DA SAÚDE**

Mossoró – RN
2025

FELIPE GABRIEL QUEIROZ REGO

**RECOMENDAÇÃO PERSONALIZADA DE CONTEÚDO PARA SUPORTE À
APRENDIZAGEM INFORMAL NO CONTEXTO DA SAÚDE**

Projeto de dissertação apresentado ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal Rural do Semi-Árido como requisito parcial para obtenção do título de Mestre em Ciência da Computação.

Linha de Pesquisa: Engenharia de *Software*

Orientador: Prof. Dr. Francisco Milton Mendes Neto.

Mossoró/RN
2025

© Todos os direitos estão reservados a Universidade Federal Rural do Semi-Árido. O conteúdo desta obra é de inteira responsabilidade do (a) autor (a), sendo o mesmo, passível de sanções administrativas ou penais, caso sejam infringidas as leis que regulamentam a Propriedade Intelectual, respectivamente, Patentes: Lei nº 9.279/1996 e Direitos Autorais: Lei nº 9.610/1998. O conteúdo desta obra tomar-se-á de domínio público após a data de defesa e homologação da sua respectiva ata. A mesma poderá servir de base literária para novas pesquisas, desde que a obra e seu (a) respectivo (a) autor (a) sejam devidamente citados e mencionados os seus créditos bibliográficos.

RR343 REGO, FELIPE.

r RECOMENDAÇÃO PERSONALIZADA DE CONTEÚDO PARA
SUPORTE À APRENDIZAGEM INFORMAL NO
CONTEXTO DA SAÚDE / FELIPE REGO. - 2025.
80 f. : il.

Orientador: FRANCISCO MENDES.

Dissertação (Mestrado) - Universidade Federal
Rural do Semi-árido, Programa de
Pós-graduação em Ciência da Computação, 2025.

1. sistema de recomendação personalizada. 2.
aprendizagem informal. 3. saúde gestantes. I.
MENDES, FRANCISCO, orient. II. Título.

Ficha catalográfica elaborada por sistema gerador automático em
conformidade com AACR2 e os dados fornecidos pelo autor(a).
Biblioteca Campus Mossoró / Setor de Informação e Referência
Bibliotecária: Keina Cristina Santos Sousa e Silva
CRB: 15/120

O serviço de Geração Automática de Ficha Catalográfica para Trabalhos de Conclusão de Curso (TCC's) foi desenvolvido pelo Instituto de Ciências Matemáticas e de Computação da Universidade de São Paulo (USP) e gentilmente cedido para o Sistema de Bibliotecas da Universidade Federal Rural do Semi-Árido (SISBI-UFERSA), sendo customizado pela Superintendência de Tecnologia da Informação e Comunicação (SUTIC) sob orientação dos bibliotecários da instituição para ser adaptado às necessidades dos alunos dos Cursos de Graduação e Programas de Pós-Graduação da Universidade.

FELIPE GABRIEL QUEIROZ REGO

**RECOMENDAÇÃO PERSONALIZADA DE CONTEÚDO PARA SUPORTE À
APRENDIZAGEM INFORMAL NO CONTEXTO DA SAÚDE**

Projeto de dissertação apresentado ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal Rural do Semi-Árido como requisito parcial para obtenção do título de Mestre em Ciência da Computação.

Linha de Pesquisa: Engenharia de *Software*

Orientador: Prof. Dr. Francisco Milton Mendes Neto.

Defesa em: 06 / 06 / 2025.

BANCA EXAMINADORA

Francisco Milton Mendes Neto, Prof. Dr. (UFERSA)
Presidente

Bruno de Sousa Monteiro, Prof. Dr. (UFERSA)
Membro Examinador

Gustavo Augusto Lima de Campos, Prof. Dr. (UECE)
Membro Externo

AGRADECIMENTOS

A caminhada durante o mestrado foi repleta de desafios, aprendizados e transformações que só foram possíveis graças ao apoio e incentivo de pessoas especiais.

Em primeiro lugar, agradeço profundamente à minha família, especialmente aos meus pais e irmãs, que foram meu alicerce em todos os momentos. Obrigado pela força, paciência e amor incondicional, que me impulsionaram a seguir em frente mesmo nos dias mais difíceis.

Ao meu orientador, Professor Dr. Milton Mendes, expresso minha mais sincera gratidão por toda a dedicação, empenho e confiança depositados em mim ao longo desta jornada. Seus ensinamentos e orientações foram fundamentais para o desenvolvimento deste trabalho e para minha formação acadêmica e pessoal.

Aos meus amigos e irmãos de caminhada, agradeço pelo apoio constante, pelas palavras de encorajamento e pela presença firme nos momentos em que precisei.

A todos que, direta ou indiretamente, contribuíram para a realização deste sonho, meu muito obrigado.

RESUMO

A gravidez é um período marcado por transformações profundas e por uma crescente demanda por informações de saúde confiáveis. No entanto, a abundância de conteúdos disponíveis dificulta o acesso a materiais relevantes e personalizados. Este trabalho propõe um sistema híbrido de recomendação personalizada, desenvolvido para atender às necessidades específicas das gestantes, combinando técnicas de filtragem colaborativa, análise de similaridade baseada em conteúdo e recomendações por moderadores. A arquitetura do sistema foi projetada de forma modular, integrando pesos ajustáveis para priorizar conteúdos conforme o perfil da usuária, com base em seus interesses e histórico de interações. Para avaliar a eficácia do sistema, foi conduzida uma simulação com usuárias fictícias e conteúdos categorizados. O experimento utilizou métricas de desempenho, análise por faixa etária e simulações com diferentes perfis e contextos. Os resultados demonstraram a capacidade do sistema em entregar recomendações relevantes, promovendo a personalização, o engajamento e o suporte à aprendizagem informal durante a gestação. A plataforma Higia Way, utilizada como estudo de caso, viabilizou a aplicação prática do modelo, evidenciando avanços na qualidade da informação acessada pelas gestantes e impacto positivo na sua autonomia e bem-estar.

Palavras-Chave: sistema de recomendação personalizada, aprendizagem informal, saúde gestantes.

ABSTRACT

Pregnancy is a period marked by profound transformations and an increasing demand for reliable health information. However, the abundance of available content makes it difficult to access relevant and personalized materials. This study proposes a hybrid personalized recommendation system designed to meet the specific needs of pregnant women by combining collaborative filtering, content-based similarity analysis, and moderator-driven recommendations. The system architecture was designed in a modular fashion, incorporating adjustable weights to prioritize content according to the user's profile, based on her interests and interaction history. To evaluate the system's effectiveness, a simulation was conducted using fictitious users and categorized content. The experiment employed performance metrics, age group analysis, and simulations with varying profiles and contexts. The results demonstrated the system's ability to deliver relevant recommendations, fostering personalization, user engagement, and support for informal learning during pregnancy. The Higia Way platform, used as a case study, enabled the practical application of the model, highlighting improvements in the quality of information accessed by pregnant women and a positive impact on their autonomy and well-being.

Keywords: personalized recommendation system, informal learning, pregnant health.

LISTA DE TABELAS

Tabela 1 - Cálculo de Pesos nas Tags.....	39
Tabela 2 - Ordenação dos Posts.....	40
Tabela 3 - Cálculo do Moderador.....	42
Tabela 4 - Cálculo do similaridades combinadas para três posts.....	48
Tabela 5 - Exemplo como o cache funciona para diferentes requisições.....	51
Tabela 6 - Dados das Usuárias Simuladas.....	60
Tabela 7 - Categorização dos Itens.....	61
Tabela 8 - Ponderação Utilizada.....	66
Tabela 9 - Métricas de Desempenho.....	67
Tabela 10 - Resultado da Recomendação Híbrida.....	69
Tabela 11 - Resultado da Recomendação Híbrida (com o melhor conteúdo recomendado avaliado).....	69
Tabela 12 - Faixa etária das gestantes: 18-45 anos.....	71
Tabela 13 - Status de Gravidez.....	71
Tabela 14 - Distribuição de Semanas de Gestação.....	71
Tabela 15 - Simulação dos pesos das tags.....	72
Tabela 16 - Simulação da recomendação de acordo com a faixa etária 18-25 anos.....	72
Tabela 17 - Simulação da recomendação de acordo com a faixa etária 26-35 anos.....	73
Tabela 18 - Simulação da recomendação de acordo com a faixa etária 36-45 anos.....	73
Tabela 19 - Resultado da simulação com contexto neutro e usuária de perfil definido.	75
Tabela 20 - Resultado da simulação com contexto definido e usuário de perfil neutro.	75

LISTA DE FIGURAS

Figura 1 - Tela de Login e Cadastro.....	18
Figura 2 - Tela Inicial Post.....	19
Figura 3 - Tela do Conteúdo do Post.....	20
Figura 4 - Recomendação com Filtragem Colaborativa.....	24
Figura 5 - Arquitetura do Sistema de Recomendação Híbrida.....	38

SUMÁRIO

1. INTRODUÇÃO.....	13
1.1 Motivação.....	14
1.2 Justificativa.....	14
1.3 Questão de Pesquisa.....	15
1.4 Objetivos.....	15
1.4.1 Objetivo Geral.....	15
1.4.2 Objetivos Específicos.....	16
1.5 Apresentação do Higia Way.....	16
1.6 Método de Pesquisa.....	21
2. REFERENCIAL TEÓRICO.....	23
2.1 Sistema de Recomendação.....	23
2.1.1 Recomendação baseada em conteúdo.....	23
2.1.2 Recomendação Colaborativa.....	24
2.1.3 Recomendação Colaborativa Baseada em Vizinhança.....	25
2.1.4 Recomendação Baseado em Modelo.....	26
2.1.5 Recomendação de sistemas de base de conhecimento.....	27
2.1.6 Recomendação híbrida.....	27
2.2 Aprendizagem Informal.....	28
2.3 Saúde Materna.....	29
3. TRABALHOS RELACIONADOS.....	30
3.1 Diferencial da abordagem de recomendação de proposta.....	32
4. DESENVOLVIMENTO DO SISTEMA DE RECOMENDAÇÃO.....	34
4.1 Coleta de Dados.....	34
4.2 Preparação e Limpeza dos Dados.....	35
4.3 Desenvolvimento do Modelo.....	37
4.3.1 Cálculo de Interesses do Usuário.....	39

4.3.1.1	Processamento de Tags Declaradas.....	39
4.3.1.2	Ordenação dos Posts.....	40
4.3.2	Incorporação de Recomendações de Moderadores.....	41
4.3.3	Integração com Outras Técnicas de Recomendação.....	43
4.3.4	Cálculo de Similaridade entre Usuário e Post.....	43
4.3.5	Similaridade entre Usuários (Recomendação Colaborativa).....	45
4.3.6	Sistema Híbrido de Recomendação.....	48
4.3.7	Caching e Performance.....	50
4.3.8	Tecnologias Utilizadas.....	52
4.3.8.1	Back-End.....	53
4.3.8.1.1	Linguagem de Programação: Java.....	53
4.3.8.1.2	Banco de Dados: PostgreSQL.....	54
4.3.8.1.3	Sistema de Cache: Ehcache.....	54
4.3.8.2	Front-End.....	55
4.3.8.2.1	React Native.....	55
5.	VALIDAÇÃO DO SISTEMA DE RECOMENDAÇÃO HÍBRIDA.....	56
5.1	Validação Simulada.....	56
5.2	Arquitetura do Ambiente de Teste.....	56
5.2.1	O fluxo do experimento.....	57
5.2.2	Geração de Dados Sintéticos.....	58
5.3	Perfil das Usuárias Cadastradas.....	59
5.3.1	Análise dos Perfis.....	60
5.4	Base de Dados de Conteúdos.....	61
5.4.1	Categorização dos Itens.....	61
5.4.2	CrITÉrios de Seleção.....	61
5.5	Processamento das Recomendações Híbridas.....	62
5.5.1	Filtragem Colaborativa (User-Based CF).....	63
5.5.2	Filtragem por Moderador (MF).....	64
5.5.3	Similaridade de Conteúdo (SC).....	65

5.6 Resultados e Análise.....	67
5.7 Organização dos Experimentos.....	68
5.8 Simulação.....	69
5.9 Análise dos Resultados da Simulação.....	74
6. CONCLUSÃO E RECOMENDAÇÃO PARA TRABALHOS FUTUROS.....	77
6.1 Limitações Identificadas.....	77
6.2 Trabalhos Futuros.....	78
6.2.1 Expansão da Validação Empírica.....	78
6.2.2 Aprimoramentos Técnicos.....	79
6.2.3 Sustentabilidade e Escalabilidade.....	79
REFERÊNCIAS.....	80

1. INTRODUÇÃO

A aprendizagem informal desempenha um papel fundamental na busca de informações e no empoderamento das pessoas em relação à sua própria saúde. No contexto da gravidez, as futuras mães enfrentam uma infinidade de perguntas e preocupações, tornando a obtenção de informações confiáveis e relevantes uma necessidade premente. No entanto, a personalização dessas informações de acordo com o perfil individual e prontuário médico de cada gestante é uma abordagem que ainda precisa ser amplamente explorada (CASTRO; ARAÚJO, 2006).

De acordo com os conceitos de aprendizagem informal, apresentados por Laal (2020), é possível entender que a busca por informações no contexto da saúde, especialmente durante a gravidez, pode ocorrer de forma não oficial e não programada. Nesse sentido, a troca de experiências com outras gestantes e o acesso a recursos on-line, como a internet e redes sociais, desempenham um papel significativo na obtenção de conhecimentos e suporte.

A gravidez é um momento especial na vida de uma mulher, repleto de mudanças físicas e emocionais. Nesse período, as futuras mães devem ter acesso a conteúdo que as ajude a compreender as mudanças que ocorrem em seu corpo, promover hábitos alimentares saudáveis, praticar o autocuidado e receber orientações sobre o pré-natal.

No entanto, as abordagens tradicionais para fornecer informações gerais sobre a gravidez podem não atender adequadamente às necessidades individuais de cada mulher grávida. Cada mulher tem um perfil único que inclui fatores como idade, histórico médico, estilo de vida e preferências pessoais. Além disso, condições médicas pré-existentes podem influenciar muito a experiência e as necessidades de cuidados durante a gravidez (OPAS, 2022).

Neste contexto, as recomendações de conteúdos personalizados têm-se revelado uma solução promissora para o fornecimento de informação relevante e personalizada a todas as gestantes. Tendo como base perfis individuais e registros médicos, podemos criar conteúdo específicos para cada grávida, tendo em conta as suas necessidades e circunstâncias específicas (PERRONI, 2024).

O objetivo deste trabalho é investigar a importância e utilidade de recomendações de conteúdo personalizado no contexto da saúde materno-infantil, com foco na gravidez.

Este trabalho aborda os desafios que as mulheres grávidas enfrentam para encontrar informações confiáveis, ao mesmo tempo em que oferece a oportunidade de fornecer aconselhamento personalizado e de alta qualidade por meio de tecnologia e análise de dados. Acredita-se que essa abordagem pode facilitar o aprendizado informal e contribuir para o bem-estar da mãe e do bebê.

1.1 Motivação

A motivação por trás deste trabalho reside na convicção de que todas as gestantes merecem acesso a informações confiáveis e personalizadas para promover uma gestação saudável e segura. Acreditamos que o desenvolvimento e a aplicação de um sistema robusto de recomendação de conteúdo têm o potencial de contribuir de maneira significativa para a melhoria da experiência informacional das gestantes, capacitando-as a enfrentar os desafios da gravidez com maior confiança e conhecimento.

1.2 Justificativa

A gravidez é um período crucial na vida de uma mulher, repleto de mudanças físicas, emocionais e sociais, que exigem atenção especial à saúde e bem-estar tanto da mãe quanto do bebê. No contexto da saúde materna, a busca por informações confiáveis e relevantes desempenha um papel fundamental no apoio à gestante durante essa jornada. No entanto, muitas vezes, as gestantes enfrentam desafios ao acessar e interpretar informações de saúde precisas e personalizadas que atendam às suas necessidades individuais.

A implementação de sistemas de recomendação personalizada de conteúdo surge como uma resposta promissora para suprir essa lacuna, oferecendo suporte à aprendizagem informal e auxiliando as gestantes na compreensão e gestão de sua saúde durante a gravidez. Nesse sentido, este trabalho foi desenvolvido devido a diversas razões:

- **Necessidade de Acesso a Informações Confiáveis:** As gestantes frequentemente buscam orientação sobre uma ampla gama de tópicos relacionados à gravidez, desde cuidados pré-natais até sinais de alerta

durante o parto. Dispor de um sistema que recomende conteúdos confiáveis e personalizados pode ajudar a preencher essa necessidade crucial de informações.

- **Potencial para Melhoria da Saúde Materna:** Ao capacitar as gestantes com conhecimento relevante e adaptado às suas necessidades individuais, este trabalho tem o potencial de melhorar os resultados de saúde materna, promovendo práticas saudáveis, reduzindo a ansiedade e incentivando uma abordagem proativa para o cuidado durante a gravidez.
- **Empoderamento e Autonomia das Gestantes:** Ao fornecer acesso a informações confiáveis e personalizadas, o sistema de recomendação pode capacitar as gestantes a tomar decisões informadas sobre sua saúde e a se envolver ativamente em seu próprio processo de cuidado, promovendo assim maior autonomia.
- **Contribuição para a Pesquisa e Desenvolvimento Tecnológico:** Este trabalho contribui para a interseção entre saúde materna e tecnologia, explorando novas abordagens para melhorar o acesso e a compreensão de informações de saúde durante a gravidez. Além disso, promove avanços no campo de sistemas de recomendação personalizada, com potencial impacto em outras áreas da saúde.

1.3 Questão de Pesquisa

A sociedade contemporânea é caracterizada por um vasto acesso à informação, e a área da saúde não é uma exceção. Diante da sobrecarga de dados, surge a necessidade crucial de empregar tecnologias eficientes para recomendar conteúdos relacionados à saúde. A pergunta central desta pesquisa é: "Qual tecnologia de recomendação de conteúdo é mais eficaz em fornecer informações personalizadas e confiáveis para gestantes no contexto da saúde materno-infantil?"

1.4 Objetivos

1.4.1 Objetivo Geral

Desenvolver um sistema de recomendação personalizado de conteúdo para gestantes que será testado na plataforma Higia. O sistema será projetado para recomendar conteúdos relevantes e personalizados com base no perfil e no prontuário médico de cada gestante, visando fornecer informações e orientações adequadas à sua condição específica.

1.4.2 Objetivos Específicos

- Identificar as necessidades e demandas específicas das gestantes em relação à saúde, nutrição, exercícios e cuidados durante a gestação, levando em consideração seu perfil e prontuário médico.
- Pesquisar e desenvolver algoritmos avançados de recomendação que possam utilizar os dados do prontuário médico e o perfil da gestante para fornecer recomendações personalizadas de conteúdo relacionado à saúde durante a gestação.
- Implementar o sistema de recomendação personalizado, integrando-o ao ambiente digital da plataforma Higia, garantindo a segurança e a privacidade dos dados dos usuários.
- Avaliar a efetividade do sistema de recomendação por meio de testes e avaliações com as gestantes, coletando *feedback* e medindo a relevância e a utilidade das recomendações fornecidas.
- Investigar o impacto do sistema de recomendação personalizado na saúde e no bem-estar das gestantes, avaliando se as recomendações contribuem para a melhoria de sua condição de saúde e a adoção de hábitos saudáveis.
- Propor melhorias e recomendações para o projeto Higia com base nos resultados obtidos, visando aprimorar a eficácia e a personalização do sistema de recomendação, contribuindo para a saúde e o bem-estar das gestantes atendidas pelo projeto.

1.5 Apresentação do Higia Way

O aplicativo Higia Way foi utilizado como estudo de caso para aplicar a metodologia criada nesta pesquisa. Este aplicativo é projetado para apoiar o aprendizado de grávidas e puérperas, integrando elementos de gamificação com conteúdos relevantes

desenvolvidos por profissionais de saúde. O objetivo do Higia Way é abordar a questão das informações desatualizadas e da falta de dados consistentes e relevantes que grávidas e puérperas frequentemente encontram ao buscar informações sobre a gestação na internet.

Inserido no contexto da educação em saúde gestacional, o Higia Way foi desenvolvido como uma ferramenta educacional para ser utilizada tanto por profissionais de saúde quanto por pacientes. Ele oferece suporte, instrução e educação ao longo dos meses de gestação e nos primeiros meses de vida do bebê. Através do uso de tecnologias interativas e conteúdo validado, o aplicativo visa melhorar a qualidade e a confiabilidade das informações disponíveis, proporcionando uma experiência de aprendizagem mais eficaz e personalizada para as usuárias.

Nesta seção, serão apresentadas as principais telas do sistema, acompanhadas da descrição de suas respectivas funcionalidades.

[illegible]

As imagens acima representam as telas de login e cadastro do sistema Higia Way. Nessa etapa, a usuária realiza seu cadastro e, posteriormente, efetua o login para acessar o sistema. Na tela de cadastro, são solicitadas informações essenciais para análise do perfil da gestante, como nome, e-mail, sexo, data de nascimento, senha, se está grávida e se é sua primeira gestação.

Figura 2. Tela Inicial Post




Fonte: Autoria Própria

A Figura 03 apresenta a tela inicial do aplicativo, onde são exibidas as recomendações personalizadas de conteúdo. Essas recomendações são geradas com base nas informações fornecidas pela usuária durante o preenchimento do formulário de cadastro. A partir do perfil da gestante cadastrada, o sistema identifica suas

necessidades e interesses, sugerindo conteúdos específicos e relevantes para sua jornada de gestação.

Figura 3. Tela do Conteúdo do Post



Fonte: Autoria Própria

Na figura 4, a gestante tem acesso ao conteúdo recomendado de forma detalhada, com informações claras sobre o tema abordado. Cada post apresenta descrições que explicam os principais pontos do conteúdo, facilitando a compreensão e a aplicação das informações no dia a dia. Além disso, a usuária pode interagir com o conteúdo, deixando comentários e avaliando o quanto aquele material foi útil para sua gestação. Esses conteúdos são cuidadosamente elaborados e inseridos por profissionais

especializados na área da saúde materna, garantindo a qualidade e a confiabilidade das informações oferecidas.

Além das recomendações de conteúdo, o aplicativo oferece outras funcionalidades pensadas para apoiar a gestante de maneira interativa e prática ao longo de toda a gestação. Entre elas, destacam-se o Quiz, o Game e o Enxoval, cada um com um papel específico no processo de aprendizagem, organização e preparo para a chegada do bebê.

- **Quiz:** Essa funcionalidade apresenta perguntas e respostas relacionadas à gestação, promovendo a interação e o aprendizado de forma leve e dinâmica. O objetivo é reforçar os conhecimentos da gestante por meio de uma abordagem educativa e ao mesmo tempo divertida, estimulando a reflexão sobre temas importantes da saúde materna.
- **Game:** O jogo tem como finalidade auxiliar a gestante na preparação para a chegada do bebê, especialmente na organização do quarto do recém-nascido. De forma lúdica, a usuária pode explorar diferentes possibilidades de montagem do ambiente, desenvolvendo seu senso de planejamento e organização, além de tornar o momento mais leve e prazeroso.
- **Enxoval:** Nesta seção, a gestante pode cadastrar todos os itens adquiridos para o bebê, como roupas, fraldas, produtos de higiene e acessórios. A funcionalidade funciona como um checklist personalizado, ajudando na organização do enxoval e evitando compras desnecessárias ou esquecimentos.

Essas funcionalidades foram pensadas para tornar a experiência da gestação mais interativa, informativa e acolhedora, proporcionando suporte tanto emocional quanto prático para as futuras mães.

1.6 Método de Pesquisa

A presente pesquisa adota uma abordagem aplicada e experimental, cujo objetivo principal é o desenvolvimento de um sistema de recomendação personalizado voltado à saúde materna. O método utilizado envolveu as seguintes etapas: (i) levantamento teórico e análise de trabalhos relacionados, (ii) definição dos requisitos e arquitetura do sistema, (iii) desenvolvimento de um protótipo funcional integrado à plataforma Higia Way, e (iv) validação do sistema por meio de simulações com dados sintéticos. Cada etapa foi conduzida de forma iterativa, com base em princípios de

engenharia de software, visando garantir a consistência, relevância e eficácia do sistema proposto.

2. REFERENCIAL TEÓRICO

Nesta seção, serão expostos os fundamentos teóricos essenciais para a compreensão da pesquisa em questão, que se dedica à Recomendação Personalizada de Conteúdo para Apoio à Aprendizagem Informal no âmbito da Saúde Materna. A abordagem contempla conceitos pertinentes aos Sistemas de Recomendação, Sistemas de Recomendação baseados em conteúdo e à Recomendação fundamentada na filtragem colaborativa, Aprendizagem Informal e Saúde Materna.

2.1 Sistema de Recomendação

Sistemas de Recomendação são instrumentos e métodos de software que oferecem sugestões de itens mais propensos a interessar a um usuário específico. Conforme destacado por Raza et al. (2024), o propósito fundamental de um sistema de recomendação é apresentar listas personalizadas de objetos "recomendados" aos seus usuários, sendo capaz de prever avaliações ou atribuir notas a itens ainda desconhecidos por determinado usuário.

Sistemas de recomendação, que são amplamente utilizados em comércio eletrônico, entretenimento e serviços, oferecem sugestões de itens ao usuário final. Essas recomendações são resultado da combinação de abordagens como conteúdo, filtragem colaborativa e conhecimento. Para serem eficazes, esses sistemas devem prever ou comparar a importância dos itens, proporcionando sugestões relevantes. Diversas técnicas são propostas como base, variando de acordo com as fontes de dados utilizadas. Em alguns casos, as preferências de outros usuários são a base, enquanto em outros são as descrições do item em si. As duas técnicas serão detalhadas a seguir. (MA; LI; LIU, 2024).

2.1.1 Recomendação baseada em conteúdo

Sistemas de recomendação baseados em conteúdo analisam as características dos itens para sugerir aqueles que se assemelham aos que o usuário demonstrou interesse anteriormente. Por outro lado, a filtragem colaborativa identifica padrões de preferências entre diversos usuários, recomendando itens que indivíduos com gostos

semelhantes aprovaram. Conforme destacado pela IBM (2024), a filtragem baseada em conteúdo utiliza os atributos dos itens para selecionar e retornar aqueles relevantes para o usuário. Além disso, a IBM (2024) explica que a filtragem colaborativa agrupa usuários com comportamentos semelhantes e sugere itens com base nas preferências coletivas do grupo.

A abordagem de recomendação baseada em conteúdo foca na análise das características dos itens previamente apreciados pelo usuário para fornecer sugestões personalizadas. Conforme destacado pela IBM (2024), esse método utiliza os atributos dos itens para criar um perfil de interesses do usuário, permitindo a recomendação de novos itens que compartilham características semelhantes aos já preferidos. A precisão desse modelo em refletir as preferências do usuário é crucial para o sucesso do sistema de recomendação.

2.1.2 Recomendação Colaborativa

Na filtragem colaborativa, o sistema sugere itens ao usuário com base nos interesses de usuários similares no passado. A similaridade entre usuários é calculada a partir de seus históricos de classificações (SANTOS, 2023). Por exemplo, na Figura 1, o sistema identifica usuários similares ao usuário principal e recomenda itens com base nas avaliações desses usuários.

Figura 4. Recomendação com Filtragem Colaborativa



Fonte: Patrício (2021).

A ideia principal é se concentrar na interação entre usuários e conteúdos, examinando a similaridade nos gostos entre pares de usuários e fazendo recomendações com base nessa afinidade. Em outras palavras, o que é considerado relevante para mim pode também ser relevante para alguém com interesses semelhantes. Por exemplo, se a usuária **i** aprecia os livros A, B e C, e o usuário **j** gosta dos livros B, C e D, suas preferências indicam interesses semelhantes, permitindo a recomendação do livro A para **j** e do livro D para **i** (SANTOS, 2023). Tem-se que os métodos de filtragem colaborativa podem ser divididos nas duas classes gerais baseados em vizinhança e modelo.

2.1.3 Recomendação Colaborativa Baseada em Vizinhança

Na abordagem de filtragem colaborativa baseada em vizinhança, as avaliações usuário-item armazenadas no sistema são diretamente utilizadas para prever classificações de novos itens. Isso ocorre por meio de duas estratégias conhecidas como recomendação *user-based* (baseada no usuário) ou *item-based* (baseada no item). Segundo Santos (2023), a técnica de filtragem colaborativa baseada em vizinhança segue essencialmente três passos:

1. Calcular o peso de cada usuário em relação à sua similaridade com o usuário-alvo (métrica de similaridade).
2. Selecionar um subconjunto de usuários com maiores similaridades (vizinhos) para serem considerados na predição.
3. Normalizar as avaliações e realizar as predições ponderando as avaliações dos vizinhos com seus pesos.

No primeiro passo, a definição da similaridade pode ser realizada por meio da aplicação de diversos coeficientes, como Cosseno, Pearson, entre outros (MATOS, 2021). Diversos métodos têm sido empregados para calcular a similaridade entre usuários, sendo a maioria baseada em avaliações prévias de itens feitas por ambos. As abordagens mais comuns são correlação e cosseno, com o coeficiente de Pearson, apresentado na Equação (1), sendo uma medida popular para análise de correlação.

$$p = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2} \cdot \sqrt{\sum_{i=1}^N (y_i - \bar{y})^2}} \quad (1)$$

Na metodologia que utiliza o cosseno, os usuários x e y são considerados vetores em um espaço m -dimensional, onde $m = |S_{xy}|$. Assim, a similaridade entre esses dois vetores pode ser determinada ao calcular o cosseno do ângulo formado entre eles.

A recomendação colaborativa sugere itens aos usuários com base nas preferências de outros usuários similares. A principal diferença entre a recomendação colaborativa e a baseada em vizinhança é a abordagem específica de similaridade. Na recomendação baseada em vizinhança, as avaliações usuário-item armazenadas são usadas diretamente para prever novas classificações, através de duas estratégias: user-based (baseada no usuário) ou item-based (baseada no item) (MATOS, 2021). Este método envolve três passos principais: calcular a similaridade, selecionar os vizinhos mais similares e ponderar as avaliações para realizar previsões. A similaridade é determinada por coeficientes como o Cosseno ou Pearson (SANTOS, 2023).

2.1.4 Recomendação Baseado em Modelo

Ao contrário dos métodos baseados em vizinhança, os métodos baseados em modelos utilizam classificações para aprender um modelo, que é empregado para fazer previsões (CARDOSO, 2022). Esses algoritmos usam o banco de dados para estimar ou aprender o modelo, podendo incluir clusterização, redes Bayesianas, regras de associação e modelos de fatoração de matrizes. Abaixo, um detalhamento do modelo específico de fatoração de matrizes usado na filtragem colaborativa.

A decomposição de matrizes em valor singular é uma técnica comum de fatoração de matrizes na filtragem colaborativa (VARGAS, 2020). A decomposição de valores singulares expressa as relações entre usuários e itens linearmente por meio de fatores. Essa decomposição resulta em duas matrizes de baixa ordem, cujo produto é uma matriz de classificação aproximada, conforme a fórmula:

$$R \approx U^t V \quad (2)$$

onde U (com $l \ll m$) é a matriz de interesse do usuário, U_{ik} é o grau de interesse do usuário i na classe k , e $\text{Sim}(a, i)$ denota a similaridade entre os usuários a, i . $I(a)$ e $I(i)$ indicam os conjuntos de itens avaliados pelos usuários a, i respectivamente, enquanto r_a e r_i são as médias das classificações dadas por a, i .

Geralmente, sistemas de recomendação que aplicam a decomposição de matrizes seguem um padrão onde a matriz de classificações é fatorada em um produto de matrizes representando fatores latentes para os itens e usuários.

2.1.5 Recomendação de sistemas de base de conhecimento

Os sistemas de recomendação baseados em conhecimento são principalmente utilizados em cenários onde não há um padrão constante de atividade por parte dos usuários, conforme observado por Matos (2020). Eles são projetados para levar em conta domínios específicos ao fazer recomendações, dependendo fortemente de dados estruturados com atributos relacionais em vez de simples texto ou palavras-chave.

Segundo Mascarenhas (2020), tais sistemas são adaptados para atender às necessidades específicas de seu campo de aplicação, permitindo que sejam implementados em áreas particulares. Além disso, permitem a correlação entre propriedades e ações dentro do sistema, possibilitando recomendações precisas que correspondam a necessidades particulares, refletindo assim a essência do domínio em questão.

2.1.6 Recomendação híbrida

A abordagem híbrida de recomendação surge como resposta às dificuldades encontradas na análise de conteúdo não estruturado e na complexidade da extração e análise de dados não textuais, problemas identificados nos sistemas de recomendação tradicionais, conforme descrito por Schrammel (2023).

Essa estratégia é especialmente relevante para recomendar itens que incluem informações textuais, tipicamente abordados por sistemas de filtragem baseados em conteúdo. Desafios adicionais surgem na interpretação semântica de textos que, apesar de compartilharem termos similares, podem divergir significativamente em intenção.

Nos sistemas de recomendação colaborativos, as principais limitações estão na coleta de informações dos usuários, com problemas notáveis incluindo a hesitação em recomendar ações não previamente avaliadas por outros usuários, bem como a

variabilidade de avaliações em contextos com poucos usuários mas muitos dados, conforme apontado por Matos (2020).

Para atenuar essas questões, adota-se uma abordagem híbrida que combina dois ou mais métodos de recomendação, aproveitando as forças de cada filtragem enquanto se contornam os desafios que surgiriam ao depender de um único sistema, uma solução sugerida por Santos (2023).

2.2 Aprendizagem Informal

O aprendizado informal, conforme definido por Segundo De Souza Boeira, Larentis e Da Costa (2022), "refere-se a oportunidades naturais que surgem no cotidiano, onde a própria pessoa controla seu processo de aprendizagem. Além disso, caracteriza-se como predominantemente experiencial, prática e não-institucional". Esse processo contínuo de aquisição de habilidades, conhecimentos e competências ocorre fora dos ambientes educacionais formais, como escolas e universidades, destacando-se pela espontaneidade e pela adaptabilidade às necessidades e interesses individuais.

Ao contrário do aprendizado formal, que segue um currículo estruturado e é frequentemente limitado a um ambiente de sala de aula, o aprendizado informal se manifesta através de interações sociais, experiências de trabalho, hobbies e o uso de mídia e tecnologia, enfatizando a importância da curiosidade e da auto-iniciativa na exploração de novos conhecimentos e habilidades (HUZAIRIN et al., 2020).

A relevância do aprendizado informal reside na sua capacidade de complementar e enriquecer o conhecimento formal, proporcionando uma perspectiva mais ampla e diversificada sobre vários assuntos. Ele capacita os indivíduos a se adaptarem melhor às mudanças rápidas do mercado de trabalho e às exigências sociais, fomentando a aprendizagem ao longo da vida e o desenvolvimento contínuo de competências relevantes. Além disso, o aprendizado informal pode facilitar a inclusão social, ao oferecer oportunidades de aprendizagem para aqueles que, por diversas razões, podem não ter acesso à educação formal (GIMENEZ, 2020). Em resumo, o aprendizado informal desempenha um papel crucial no desenvolvimento pessoal e profissional, oferecendo uma abordagem educacional mais flexível e personalizada.

2.3 Saúde Materna

A saúde materna abrange um amplo espectro de pesquisas, teorias e práticas focadas na promoção, proteção e melhoria da saúde de mulheres durante a gravidez, parto e pós-parto. Essa área envolve o estudo de aspectos físicos, mentais e sociais da saúde materna, destacando a importância do acesso a cuidados pré-natais de qualidade, acompanhamento durante o trabalho de parto e o pós-parto, além da prevenção e tratamento de complicações (WHO, 2024). As teorias subjacentes à saúde materna reconhecem a complexidade das necessidades das mulheres e a importância de uma abordagem holística que inclua suporte social, econômico e ambiental para garantir resultados positivos tanto para as mães quanto para os bebês (DOS SANTOS FIGUEIREDO et al., 2022).

Estudos recentes têm enfatizado a necessidade de políticas de saúde pública que enderecem desigualdades sociais e de acesso aos serviços de saúde, visando a redução da mortalidade materna e neonatal (COSTA et al. 2022). A Organização Mundial da Saúde (OMS) e outras entidades internacionais propõem diretrizes baseadas em evidências para a melhoria da qualidade dos cuidados maternos, incluindo a necessidade de sistemas de saúde robustos, capacitação profissional e envolvimento comunitário (WHO, 2024). O enfoque em práticas baseadas em evidências, como o acompanhamento pré-natal adequado, métodos de parto seguros e o apoio à amamentação, é fundamental para avançar na saúde materna e infantil globalmente. A interdisciplinaridade e a colaboração internacional são aspectos chave para o desenvolvimento de estratégias eficazes que possam ser adaptadas às diversas realidades socioculturais e econômicas enfrentadas pelas mulheres ao redor do mundo.

3. TRABALHOS RELACIONADOS

Este capítulo trata de demonstrar trabalhos que propõem soluções computacionais aplicadas à saúde. Portanto, a fim de entender os problemas enfrentados e como foram solucionados pela comunidade científica, este estudo selecionou e analisou os seguintes trabalhos:

No trabalho de Silva *et al.* (2019) sobre sistemas de recomendação na área da saúde, os autores enfocam a avaliação de tais sistemas principalmente pela satisfação do usuário, uma abordagem comum para entender a aceitação ou rejeição das recomendações fornecidas. Para medir a eficácia de seu algoritmo de recomendação, eles utilizaram a métrica de precisão (Precision), calculada como a proporção de conteúdos recomendados que são efetivamente relevantes para o usuário (Verdadeiros Positivos) em relação ao total de recomendações feitas, incluindo aquelas não relevantes (Falsos Positivos). A escolha da métrica de precisão foi justificada pela natureza do algoritmo, que não considera conteúdos negativos (não há análise de Falsos Negativos ou Verdadeiros Negativos), alinhando-se com os objetivos propostos pelo sistema de recomendação. Eles argumentam que, dado o foco do algoritmo, outras métricas como Recall, False Positive Rate e F-measure (F1) foram descartadas por necessitarem da análise de resultados negativos.

Brandão (2020) criou um sistema inovador de recomendação para fármacos usados no tratamento do câncer. Este estudo centrou-se no emprego de métodos avançados de processamento de imagem, incluindo wavelets, visando determinar a similaridade entre diferentes linhas celulares. O objetivo era investigar se essas técnicas poderiam oferecer estimativas de similaridade mais precisas, contribuindo assim para aprimorar a eficácia das recomendações fornecidas.

No trabalho de Pimenta (2022), foram desenvolvidos algoritmos de recomendação com o intuito de sugerir os medicamentos mais adequados para tratamentos de pacientes com câncer, especificamente direcionados para uma linha celular particular de cada paciente. O projeto se divide em duas fases principais: a primeira foca em calcular a similaridade entre a linha celular do paciente e outras linhas celulares na base de dados, para identificar as mais similares. A segunda fase utiliza as similaridades encontradas para recomendar medicamentos que se mostraram eficazes para as linhas celulares identificadas como similares. Para isso, foram criados dois tipos

de algoritmos de recomendação: um baseado em filtragem colaborativa, que recomenda medicamentos eficazes com base na similaridade do DNA entre as linhas celulares, e outro não personalizado, que analisa dados de medicamentos frequentes e eficazes para um determinado órgão, proporcionando recomendações baseadas nas tendências de sucesso observadas para aquele órgão específico.

No trabalho de Batista (2020), foi desenvolvido um algoritmo de recomendação alimentar utilizando a técnica de filtragem colaborativa baseada em itens. Esse algoritmo analisa tanto as avaliações de alimentos feitas por outros usuários quanto pelo próprio usuário, para recomendar alimentos classificados por ordem decrescente de preferência. Antes de fazer recomendações, o sistema considera o limite diário de nutrientes que o usuário pode consumir, comparando os valores nutricionais dos alimentos recomendados com esse limite. Caso um alimento exceda o limite estabelecido de macronutrientes e micronutrientes, ele é descartado da recomendação. O processo se inicia com a filtragem de alimentos baseada nos limites nutricionais do usuário, seguida pela análise de classificações de alimentos previamente avaliados. O sistema utiliza um objeto chamado "ClassificationsDTO" para processar todas as classificações de alimentos feitas pelos usuários. A partir daí, é construída uma lista final de alimentos recomendáveis, considerando os que se adequam às necessidades nutricionais do usuário e possuem avaliações positivas. O algoritmo emprega técnicas para calcular a similaridade entre as avaliações dos alimentos, prever classificações para alimentos ainda não avaliados pelo usuário e, finalmente, gerar uma lista de recomendações personalizadas. Estas são enviadas para um servidor web e apresentadas ao usuário através de uma aplicação, de maneira ordenada conforme a classificação prevista. Este sistema inovador oferece uma abordagem personalizada para a recomendação de alimentos, considerando tanto as preferências individuais quanto as necessidades nutricionais do usuário.

No trabalho de Figueiredo (2022), é abordado o desenvolvimento de um sistema de recomendação destinado a auxiliar no diagnóstico e tratamento de doenças mentais como ansiedade e depressão. Este sistema inovador integra componentes de um sistema pericial, uma base de dados, e um módulo web para avaliar e monitorar os níveis de depressão e ansiedade em pacientes. A pesquisa demonstrou que o uso deste sistema contribuiu para a redução dos sintomas em aproximadamente 50% dos indivíduos estudados. Diferentemente dos sistemas de recomendação baseados em

conteúdo e colaborativos, que não se mostraram adequados devido à necessidade de pré-tratamento de dados e insights específicos de especialistas, este projeto adota uma abordagem de filtragem baseada em sistemas de conhecimento. Tal escolha se alinha perfeitamente ao contexto da saúde mental, oferecendo recomendações baseadas em conhecimento especializado, o que resultou em benefícios significativos para o tratamento das condições estudadas.

3.1 Diferencial da abordagem de recomendação de proposta

Esta seção destaca os diferenciais do sistema de recomendação desenvolvido em relação às abordagens apresentadas nos trabalhos relacionados. Os estudos revisados enfatizam, de modo geral, a importância do perfil do usuário nos sistemas de recomendação. No entanto, muitos deles dependem de formulários longos para coleta de dados, o que pode ser inviável em contextos reais de uso. Por outro lado, sistemas que utilizam poucos dados enfrentam dificuldades em compreender de forma adequada as preferências do usuário.

O sistema proposto busca superar essas limitações por meio da análise automatizada de históricos de acesso e interações do usuário, o que permite gerar recomendações mais precisas e personalizadas, sem depender exclusivamente de entradas manuais. Esse mecanismo confere maior praticidade e adaptação contínua do sistema às necessidades do público-alvo.

Outro aspecto relevante é a capacidade de considerar o contexto de uso. Enquanto algumas soluções existentes ainda não conseguem adaptar as recomendações conforme variáveis contextuais, o sistema desenvolvido incorpora informações como estágio da gestação, idade da usuária e interações anteriores, o que melhora significativamente a relevância das recomendações.

Além disso, a proposta deste trabalho se diferencia pela superação da padronização excessiva dos conteúdos sugeridos, um problema comum em muitos sistemas. O modelo aqui apresentado favorece a diversidade e a personalização, promovendo uma experiência mais rica de aprendizagem informal.

Portanto, a formulação deste sistema de recomendação representa a principal contribuição científica deste estudo, pois combina boas práticas das abordagens analisadas e propõe soluções eficazes para suas limitações. O Quadro 1 a seguir resume

as principais características do sistema modelado, destacando seus elementos inovadores.

Quadro 1 – Características do Sistema de Recomendação Modelado

Similaridade	Leva em consideração as <i>tags</i> dos posts e as <i>tags</i> curtidas pelo usuário.
Moderador	Permite que um moderador indique <i>tags</i> e temas prioritários para cada usuário.
Colaborativa	Considera o grau de influência entre usuários com perfis semelhantes.

Fonte: Autoria Própria

4. DESENVOLVIMENTO DO SISTEMA DE RECOMENDAÇÃO

Este capítulo descreve o processo de desenvolvimento do sistema de recomendação proposto. As atividades foram organizadas nas seguintes etapas principais: aquisição dos dados, preparação e limpeza dos dados, modelagem do sistema de recomendação híbrida (incluindo os módulos de similaridade, moderação, filtragem colaborativa, personalização e adaptação automática), além da definição das tecnologias empregadas para sua implementação.

4.1 Coleta de Dados

A coleta inicial de conteúdos sobre gravidez, etapa fundamental para a concepção do sistema de recomendação, foi realizada por Marina de Jesus Paiva, Mestra em Enfermagem. Esse processo utilizou formulários digitais, elaborados no Google Forms, aplicados a profissionais da área da saúde, especialmente enfermeiras obstetras e agentes de saúde com experiência no atendimento a gestantes. Os formulários tinham como objetivo reunir conteúdos informativos e educativos sobre temas como amamentação, pré-natal, cuidados com o recém-nascido, parto e puerpério, baseados em boas práticas clínicas e evidências científicas. As respostas coletadas foram organizadas em planilhas eletrônicas, o que possibilitou uma estruturação adequada dos conteúdos e facilitou as etapas posteriores de categorização e análise para alimentação do sistema de recomendação.

À medida que o projeto progrediu, observou-se uma evolução significativa no método de coleta de dados, migrando para uma solução mais sofisticada e integrada, realizada por meio do próprio sistema, integrado ao sistema Higia Way. Esse sistema, desenvolvido especificamente para este fim, não apenas simplificou o processo de coleta, mas também automatizou a organização e análise dos dados, garantindo uma maior eficácia e precisão. Além de otimizar a coleta de dados, essa abordagem integrada permite uma interação direta e contínua com os usuários, enriquecendo a pesquisa com feedback em tempo real e insights valiosos, que são fundamentais para aprimorar as recomendações e suportar efetivamente a aprendizagem informal no campo da saúde materna.

Assim como o trabalho de Marina Paiva, o trabalho de Luana Pereira Barreto é de extrema importância para esta dissertação. Em seu estudo intitulado "UXCHECKMOMS: UMA METODOLOGIA PARA AVALIAÇÃO DA EXPERIÊNCIA DO USUÁRIO E USABILIDADE DE APLICATIVOS MÓVEIS PARA O PERFIL DE MULHERES GESTANTES E PUÉRPERAS", Barreto (2023) aborda os desafios inerentes à avaliação da usabilidade de aplicativos móveis, destacando a necessidade de integrar dados quantitativos, qualitativos e subjetivos em uma única validação. Sua metodologia, UXCheckmoms, é especialmente relevante pois considera aspectos emocionais e psicológicos das usuárias, fundamentais para entender as experiências de mulheres durante e após a gravidez. Esta abordagem inovadora, validada através de uma rigorosa revisão de literatura e testes empíricos com mulheres grávidas, oferece uma estrutura robusta para a avaliação contínua da usabilidade, proporcionando insights valiosos para a criação de aplicativos mais eficazes e sensíveis às necessidades das gestantes.

Portanto, citar os trabalhos enriquece a fundamentação teórica e metodológica desta dissertação, permitindo que as recomendações personalizadas sejam não apenas tecnicamente eficientes, mas também adequadas ao perfil emocional e comportamental das usuárias.

4.2 Preparação e Limpeza dos Dados

O pré-processamento dos dados foi realizado de forma semiautomatizada, combinando procedimentos manuais e scripts desenvolvidos especificamente para esse fim. Essa etapa foi essencial para garantir a qualidade e a consistência das informações utilizadas no sistema de recomendação. Os dados inicialmente coletados foram organizados em planilhas eletrônicas e, em seguida, tratados por meio de rotinas desenvolvidas em Python.

Inicialmente, os dados passaram por um processo de deduplicação para remover postagens idênticas inseridas por diferentes fontes, bem como a correção de erros de digitação em *tags* associadas aos conteúdos. Além disso, as avaliações fornecidas pelos usuários foram verificadas para garantir a consistência das informações.

A normalização dos dados foi um aspecto crítico para assegurar a padronização das unidades de medida e dos formatos temporais. Por exemplo,

informações sobre idade gestacional foram convertidas para semanas, evitando inconsistências entre registros que utilizavam formatos variados, como "5 meses" ou "20 semanas". Essa uniformização permitiu uma comparação mais eficiente entre os conteúdos e facilitou a aplicação dos algoritmos de recomendação.

Além disso, foram adotadas estratégias específicas para lidar com dados ausentes. Quando a ausência de um dado essencial, como a categoria do conteúdo, poderia comprometer a análise, utilizou-se a imputação baseada na similaridade com postagens previamente categorizadas. Já para atributos numéricos, como as avaliações dos usuários, a mediana das avaliações do mesmo tipo de conteúdo foi usada para minimizar o impacto da escassez de dados na geração das recomendações.

Um ponto de destaque no processo de normalização foi o aprimoramento da categorização das *tags* associadas aos conteúdos. Para isso, foram exploradas diferentes abordagens:

- Normalização com Dicionário de Sinônimos, unificando termos semelhantes para evitar redundâncias.
- Normalização com Categorização Hierárquica, organizando os termos em categorias estruturadas para melhorar a precisão da recomendação.
- Normalização com API de Processamento de Linguagem Natural, automatizando o reconhecimento e a padronização das *tags*.
- Normalização com Distância de Levenshtein, aplicando métricas de similaridade para identificar e corrigir variações de um mesmo termo.

Além da normalização das *tags*, foi realizada uma filtragem rigorosa para remover ruídos nos dados. Postagens com títulos excessivamente genéricos ou sem *tags* associadas foram analisadas para verificar se poderiam ser enriquecidas com informações adicionais ou se deveriam ser descartadas. Esse refinamento foi fundamental para garantir que apenas conteúdos relevantes e de qualidade fossem considerados pelos algoritmos.

Com a conclusão dessas etapas, o sistema passou a operar sobre um conjunto de dados mais limpo, estruturado e coerente, permitindo que os algoritmos de recomendação identificassem e sugerissem conteúdos com maior precisão. Esse processo foi essencial para oferecer uma experiência de aprendizagem personalizada e eficaz no contexto da saúde materna (ENGINEERING BRASIL, 2023).


4.3 Desenvolvimento do Modelo

A solução desenvolvida neste trabalho é um Sistema de Recomendação Híbrida, integrado ao contexto da saúde materna, funcionando de forma independente e garantindo a consistência do modelo híbrido proposto.

O modelo tem como objetivo fornecer apoio à aprendizagem informal, com foco em mães e gestantes, oferecendo recomendações de conteúdos personalizados que auxiliem no cuidado com a saúde materna. Dessa forma, busca-se contribuir para a melhoria da qualidade de vida das usuárias, fornecendo informações alinhadas às suas necessidades, interesses e condições específicas.

A arquitetura do Sistema de Recomendação Híbrida foi projetada de forma modular e em camadas, onde cada componente é responsável por implementar uma técnica específica de filtragem e seleção de conteúdo. Essa organização promove maior flexibilidade, facilitando a integração de novas funcionalidades e tornando o sistema expansível e altamente adaptável às demandas futuras. A abordagem híbrida proposta combina o melhor de cada técnica utilizada, resultando em recomendações mais precisas, personalizadas e alinhadas às necessidades e características únicas de cada usuária. Essa arquitetura, detalhada na Figura 2, proporciona uma base sólida e escalável para atender aos diferentes cenários e requisitos do sistema.

Figura 5. Arquitetura do Sistema de Recomendação Híbrida



Fonte: Autoria Própria

4.3.1 Cálculo de Interesses do Usuário

4.3.1.1 Processamento de *Tags* Declaradas

Cada avaliação feita pelo usuário contribui diretamente para o cálculo do peso das *tags* associadas aos conteúdos. Esse peso é determinado proporcionalmente à nota atribuída pelo usuário, sendo calculado como $\text{nota}/5$. *Tags* que recebem avaliações mais altas adquirem maior peso, exercendo uma influência significativa na priorização e relevância das recomendações geradas pelo sistema. Dessa forma, o mecanismo de atribuição de pesos reflete as preferências individuais de cada usuário, adaptando o sistema às suas necessidades específicas.

A Tabela 2 ilustra de forma clara um exemplo de perfil de usuário, destacando como as avaliações impactam os pesos atribuídos às *tags* e, consequentemente, como essas influências se traduzem na personalização das recomendações. Essa representação evidencia a eficácia do modelo em capturar e aplicar as preferências do usuário para oferecer conteúdos mais alinhados às suas expectativas.

Tabela 1 – Cálculo de Pesos nas *Tags*

TAGS	PESOS
Gestação	1,0
Mama	1,8
Lactação	0,8

Fonte: Autoria Própria

Os pesos atribuídos às *tags* desempenham um papel crucial no processo de recomendação, pois permitem comparar as características dos posts com as preferências específicas de cada usuário. Postagens com maior peso nas *tags* de interesse do usuário são priorizadas, garantindo que os conteúdos mais relevantes sejam destacados e apresentados primeiro. Esses pesos são dinâmicos e podem ser ajustados livremente por profissionais especializados na área, permitindo um refinamento constante do sistema de recomendação.

Essa flexibilidade de ajuste possibilita que os especialistas determinem a relevância de cada conteúdo em relação às diferentes *tags* criadas, alinhando as

recomendações aos objetivos específicos do sistema, como priorizar informações mais recentes, conteúdos mais confiáveis ou dados mais relevantes para um determinado perfil de usuário. Além disso, essa abordagem facilita a adaptação do sistema a diferentes contextos de aplicação, garantindo que o mecanismo de recomendação continue atendendo às necessidades tanto dos usuários quanto dos gestores do sistema.

Por meio dessa estratégia, o sistema não apenas melhora a experiência do usuário, mas também se torna uma ferramenta poderosa para gerenciar e personalizar conteúdos em tempo real, promovendo um equilíbrio entre os interesses individuais e os objetivos institucionais.

4.3.1.2 Ordenação dos Posts

A ordenação dos posts é baseada na similaridade entre as *tags* associadas ao conteúdo e o array de interesses do usuário. Essa similaridade é ponderada pelos pesos atribuídos às *tags*, refletindo a importância relativa de cada uma delas no perfil do usuário. Posts com *tags* de maior peso e correspondência direta no perfil do usuário são priorizados, resultando em recomendações mais relevantes.

Esse processo utiliza o peso acumulado das *tags* no perfil do usuário para calcular a relevância de cada post. O sistema considera tanto o alinhamento entre as *tags* quanto os pesos individuais, garantindo uma ordenação que reflete as preferências específicas do usuário. A tabela 3 mostra como é realizado.

Tabela 2 – Ordenação dos Posts

Tags do Post	Peso no Perfil do Usuário	Relevância
Mama, seios	1,8 (em "mama")	Alta
Gestação, maternidade	1,0 (em "gestação")	Moderada
Lactação, leite	0,8 (em "lactação")	Baixa
Cuidado, saúde	0,0 (sem correspondência)	Nenhuma relevância

Fonte: Autoria Própria

Nesse exemplo, os posts contendo as *tags* mama ou seios possuem maior relevância devido ao peso elevado no perfil do usuário, enquanto conteúdos

relacionados a cuidado ou saúde são considerados menos relevantes por não apresentarem correspondência direta com as *tags* de interesse.

Essa abordagem garante que o sistema priorize conteúdos mais relevantes, maximizando a personalização e a satisfação do usuário com as recomendações.

Algoritmo 1: Interesse do Usuário

```
funcao calcularInteressesUsuario(idUsuario, tagsInteresse: texto): mapa
  Cria um mapa vazio para armazenar os interesses do usuário
  mapa interesses <- {}

  Adiciona as tags declaradas pelo usuário com peso inicial de 1.0
  se (tagsInteresse != nulo e tagsInteresse != "")
    para cada tag em dividir(tagsInteresse, ",")
      interesses[tag] <- 1.0
    fimpara
  fimse

  Busca os posts avaliados pelo usuário
  lista postsUsuario <- buscarPostsUsuario(idUsuario)
  para cada post em postsUsuario
    real peso <- post.estrelas / 5.0 // Calcula o peso baseado nas estrelas
    para cada tag em dividir(post.tags, ",")
      Adiciona o peso acumulado para cada tag
      se (interesses.contem(tag))
        interesses[tag] <- interesses[tag] + peso
      senao
        interesses[tag] <- peso
      fimse
    fimpara
  fimpara

  retornar interesses
fimfuncao
```

4.3.2 Incorporação de Recomendações de Moderadores

O sistema de recomendação híbrida integra a funcionalidade de Recomendações do Moderador, um mecanismo que prioriza conteúdos considerados fundamentais para o usuário. Essas recomendações são especialmente úteis em contextos onde informações críticas precisam ser destacadas, independentemente do comportamento ou preferências do usuário. Através dessa abordagem, o moderador

exerce um papel ativo na curadoria de conteúdos, garantindo que informações essenciais sejam apresentadas de maneira consistente e eficaz.

As *tags* e temas recomendados pelo moderador recebem um peso máximo, o que posiciona os conteúdos associados no topo da lista de recomendações. Essa priorização não apenas assegura a relevância, mas também orienta o usuário a consumir informações valiosas para a sua aprendizagem ou contexto de saúde.

Fórmula para Cálculo do Peso do Moderador:

O peso final atribuído às recomendações do moderador é calculado de acordo com a seguinte fórmula:

$$\text{Peso Final} = 1.0 + (\text{Prioridade} \times 0.4) \quad (3)$$

Onde:

- Prioridade é um valor definido pelo moderador e varia de 1 a 5.
- O peso resultante varia entre 1,4 (prioridade mínima) e 3,0 (prioridade máxima).

Essa fórmula permite que o moderador ajuste a relevância relativa de cada conteúdo, assegurando flexibilidade no processo de curadoria.

Tabela 3 – Cálculo do Moderador

Tag Recomendada	Prioridade	Peso Final
Gestação segura	5	3.0
Nutrição infantil	4	2.6
Pré-natal	3	2.2
Aleitamento	2	1.8
Cuidados gerais	1	1.4

Fonte: Autoria Própria

Neste exemplo, a tag "gestação segura", considerada de prioridade máxima, recebe o peso mais alto, garantindo que conteúdos associados sejam apresentados no topo da lista de recomendações.

4.3.3 Integração com Outras Técnicas de Recomendação

O mecanismo de recomendação do moderador trabalha em sinergia com outras técnicas híbridas, como:

Similaridade: Priorização de conteúdos com maior alinhamento ao perfil do usuário.

Baseada em Conteúdo: Análise das características intrínsecas das postagens.

Filtragem Colaborativa: Identificação de padrões entre usuários com perfis semelhantes.

Ao combinar essas técnicas, o sistema garante que as recomendações atendam tanto às preferências do usuário quanto às prioridades definidas pelos especialistas, oferecendo um equilíbrio entre personalização e curadoria especializada.

Algoritmo 2: Incorporação de Recomendações de Moderadores

```
funcao incorporarRecomendacoesModeradores(idUsuario: texto, interesses: mapa)
  lista recomendacoes <- buscarRecomendacoesModeradores(idUsuario)
  para cada recomendacao em recomendacoes
    real peso <- 1.0 + (recomendacao.prioridade * 0.4)
    interesses[recomendacao.topico] <- peso
  fimpara
fimfuncao
```

4.3.4 Cálculo de Similaridade entre Usuário e Post

No contexto de sistemas de recomendação, a similaridade entre usuários e conteúdos (como posts) é uma métrica crucial para personalizar a experiência do usuário. Este tópico aborda o cálculo de similaridade entre um usuário e um post, utilizando um algoritmo que considera tanto os interesses do usuário quanto as *tags* associadas ao post. O algoritmo proposto é particularmente útil em plataformas onde os conteúdos são categorizados por *tags*, e os usuários têm perfis de interesse que podem ser ponderados.

Média da Similaridade Regular: A média é calculada dividindo a soma dos pesos das *tags* (*similaridadeRegular*) pelo número de *tags* que contribuíram (*contadorTags*). Se nenhuma tag contribuiu, o divisor é 1 para evitar divisão por zero.

$$\text{mediaSimilaridadeRegular} = \frac{\text{similaridadeRegular}}{\max(\text{contadorTags}, 1)} \quad (4)$$

Score Final com Recomendação de Moderador: Quando há uma recomendação de moderador, o score final é ajustado para refletir a importância desta recomendação.

$$\text{scoreFinal} = \text{pesoModerador} + \frac{\text{mediaSimilaridadeRegular}}{10} \quad (5)$$

Quando não há recomendação de moderador, o score final é simplesmente a média da similaridade regular.

$$\text{scoreFinal} = \text{mediaSimilaridadeRegular}$$

O algoritmo descrito abaixo calcula a similaridade entre um usuário e um post com base nos interesses do usuário e nas *tags* do post. A função `calcularSimilaridade` recebe dois parâmetros: um mapa de interesses do usuário (`interessesUsuario`) e uma lista de *tags* do post (`tagsPost`). A função retorna um valor real que representa o grau de similaridade.

Algoritmo 3: Cálculo de Similaridade entre Usuário e Post

```
funcao calcularSimilaridade(interessesUsuario: mapa, tagsPost: lista): real
  real pesoModerador <- 0
  real similaridadeRegular <- 0
  inteiro contadorTags <- 0

  para cada tag em tagsPost
    real peso <- interessesUsuario.pegar(tag, 0)
    se (peso > 1.0)
      pesoModerador <- maximo(pesoModerador, peso)
    senao se (peso > 0.0)
      similaridadeRegular <- similaridadeRegular + peso
      contadorTags <- contadorTags + 1
    fimse
  fimpara

  se (pesoModerador > 0)
    retornar pesoModerador + (similaridadeRegular / maximo(contadorTags, 1)) / 10
  senao
    retornar similaridadeRegular / maximo(contadorTags, 1)
  fimse
fimfuncao
```

Inicialização de Variáveis:

- **pesoModerador:** Armazena o maior peso encontrado para *tags* que têm peso maior que 1.0, indicando uma recomendação de moderador.
- **similaridadeRegular:** Acumula a soma dos pesos das *tags* que têm peso entre 0.0 e 1.0.
- **contadorTags:** Conta o número de *tags* que contribuíram para a similaridadeRegular.

Iteração sobre as *Tags* do Post:

- Para cada tag no post, o algoritmo verifica o peso associado no mapa de interesses do usuário.
- Se o peso for maior que 1.0, ele é considerado uma recomendação de moderador, e o maior peso é armazenado em pesoModerador.
- Se o peso for maior que 0.0 e menor ou igual a 1.0, ele é somado à similaridadeRegular, e o contadorTags é incrementado.

Cálculo do Score Final:

- Se houver pelo menos uma recomendação de moderador ($\text{pesoModerador} > 0$), o score final é calculado como a soma do pesoModerador e a média da similaridadeRegular dividida por 10.
- Caso contrário, o score final é a média da similaridadeRegular.

4.3.5 Similaridade entre Usuários (Recomendação Colaborativa)

A recomendação colaborativa é uma técnica amplamente utilizada em sistemas de recomendação para sugerir itens (como produtos, filmes, posts, etc.) com base na similaridade entre usuários. A ideia central é que usuários com interesses semelhantes tendem a gostar dos mesmos itens. Neste tópico, abordaremos o cálculo de similaridade entre dois usuários utilizando a similaridade do cosseno, uma métrica comum em sistemas de recomendação colaborativa. O algoritmo proposto calcula a similaridade entre dois usuários com base em seus perfis de interesse, representados como mapas de *tags* e pesos.

Produto Escalar: O produto escalar entre os vetores de interesse dos dois usuários é calculado como a soma dos produtos dos pesos das *tags* comuns.

$$\text{produtoEscalar} = \sum_{i=1}^n (\text{valor1}_i \times \text{valor2}_i) \quad (6)$$

Normas dos Vetores: As normas dos vetores de interesse são calculadas como a raiz quadrada da soma dos quadrados dos pesos.

$$\begin{aligned} \text{norma1} &= \sqrt{\sum_{i=1}^n (\text{valor1}_i)^2} \\ \text{norma2} &= \sqrt{\sum_{i=1}^n (\text{valor2}_i)^2} \end{aligned} \quad (7)$$

Similaridade do Cosseno: A similaridade do cosseno é calculada como a razão entre o produto escalar e o produto das normas dos vetores.

$$\text{similaridade} = \frac{\text{produtoEscalar}}{\text{norma1} \times \text{norma2}} \quad (8)$$

O resultado varia entre 0 (nenhuma similaridade) e 1 (máxima similaridade).

Similaridade 0: Indica que os usuários não compartilham interesses comuns ou que um dos usuários não têm interesses registrados.

Similaridade 1: Indica que os usuários têm perfis de interesse idênticos.

Valores intermediários: Representam o grau de similaridade entre os usuários. Quanto mais próximo de 1, mais semelhantes são os interesses.

O algoritmo logo abaixo calcula a similaridade entre dois usuários com base em seus perfis de interesse. A função `calcularSimilaridadeUsuarios` recebe dois parâmetros: dois mapas de interesses (`interesses1` e `interesses2`), onde as chaves são *tags* e os valores são pesos associados a essas *tags*. A função retorna um valor real entre 0 e 1, representando o grau de similaridade entre os usuários.

Algoritmo 4: Similaridade entre Usuários (Recomendação Colaborativa)

```
funcao combinarRecomendacoes(recomendacoesConteudo: lista,
recomendacoesColaborativas: lista): lista
  mapa combinadas <- {}

  // Processa as recomendações baseadas em conteúdo
  para cada post em recomendacoesConteudo
    post.similaridade <- post.similaridade * 0.7
    combinadas[post.id] <- post
  fimpara

  // Combina com as recomendações colaborativas
  para cada post em recomendacoesColaborativas
    se (combinadas.contem(post.id))
      combinadas[post.id].similaridade <- combinadas[post.id].similaridade +
(post.similaridade * 0.3)
    senao
      post.similaridade <- post.similaridade * 0.3
      combinadas[post.id] <- post
    fimse
  fimpara

  retornar valores(combinadas)
fimfuncao
```

Inicialização de Variáveis:

- produtoEscalar: Armazena a soma dos produtos dos pesos das *tags* comuns entre os dois usuários.
- norma1 e norma2: Armazenam a soma dos quadrados dos pesos das *tags* para cada usuário, respectivamente. Esses valores são usados para calcular as normas dos vetores de interesse.

Iteração sobre as *Tags*:

- O algoritmo itera sobre todas as *tags* presentes nos perfis de interesse dos dois usuários (obtidas pela função unirChaves).
- Para cada tag, o algoritmo obtém os pesos associados nos dois perfis (valor1 e valor2). Se uma tag não estiver presente em um dos perfis, o valor padrão é 0.
- O produto dos pesos ($\text{valor1} * \text{valor2}$) é somado ao produtoEscalar.
- Os quadrados dos pesos (valor1^2 e valor2^2) são somados às normas (norma1 e norma2).

Cálculo da Similaridade do Cosseno:

- Se uma das normas for 0, isso indica que um dos usuários não têm interesses registrados, e a similaridade é retornada como 0.
- Caso contrário, a similaridade é calculada como o produto escalar dividido pelo produto das normas dos vetores de interesse.

4.3.6 Sistema Híbrido de Recomendação

O sistema híbrido de recomendação proposto combina as melhores características das abordagens baseadas em conteúdo e colaborativas, resultando em recomendações mais precisas e diversificadas. A utilização de pesos pré definidos permite controlar a influência de cada abordagem, adaptando-se às necessidades específicas da plataforma. Essa técnica é particularmente útil em cenários onde a personalização e a diversidade são essenciais para melhorar a experiência do usuário e aumentar o engajamento.

Ajuste das similaridades das recomendações baseadas em conteúdo são multiplicadas por 0.7 (70% de peso). As similaridades das recomendações colaborativas são multiplicadas por 0.3 (30% de peso).

Combinação das similaridades para posts presentes em ambas as listas, as similaridades são somadas após o ajuste dos pesos. Para posts presentes em apenas uma das listas, a similaridade é ajustada com o peso correspondente.

Para posts em ambos os métodos:

$$\text{scoreTotal} = (\text{scoreConteúdo} \times 0.7) + (\text{scoreColaborativo} \times 0.3) \quad (9)$$

Para posts em apenas um método:

$$\text{scoreTotal} = \text{score} \times \text{pesoRespectivo} \quad (10)$$

Tabela 4 – Cálculo do similaridades combinadas para três posts

Post ID	Similaridade (Conteúdo)	Similaridade (Colaborativa)	Similaridade Combinada
1	0.8	0.5	$(0.8 * 0.7) + (0.5 * 0.3) = 0.71$
2	0.6	-	$0.6 * 0.7 = 0.42$
3	-	0.9	$0.9 * 0.3 = 0.27$

Fonte: Autoria Própria

O algoritmo apresentado abaixo combina duas listas de recomendações: uma gerada por um método baseado em conteúdo (recomendacoesConteudo) e outra por um método colaborativo (recomendacoesColaborativas). A função combinarRecomendacoes retorna uma lista de posts com similaridades ajustadas, refletindo a combinação das duas abordagens.

Algoritmo 5: Sistema Híbrido de Recomendação

```
funcao combinarRecomendacoes(recomendacoesConteudo: lista,
recomendacoesColaborativas: lista): lista
  mapa combinadas <- {}

  // Processa as recomendações baseadas em conteúdo
  para cada post em recomendacoesConteudo
    post.similaridade <- post.similaridade * 0.7
    combinadas[post.id] <- post
  fimpara

  // Combina com as recomendações colaborativas
  para cada post em recomendacoesColaborativas
    se (combinadas.contem(post.id))
      combinadas[post.id].similaridade <- combinadas[post.id].similaridade +
(post.similaridade * 0.3)
    senao
      post.similaridade <- post.similaridade * 0.3
      combinadas[post.id] <- post
    fimse
  fimpara

  retornar valores(combinadas)
fimfuncao
```

Inicialização:

- Um mapa (combinadas) é criado para armazenar os posts com suas similaridades combinadas.

Processamento das Recomendações Baseadas em Conteúdo:

- Para cada post na lista `recomendacoesConteudo`, a similaridade é ajustada multiplicando-a por 0.7 (peso atribuído às recomendações baseadas em conteúdo).
- O post é adicionado ao mapa combinadas com sua similaridade ajustada.

Combinação com as Recomendações Colaborativas:

- Para cada post na lista `recomendacoesColaborativas`, o algoritmo verifica se o post já está no mapa combinadas.
- Se estiver, a similaridade do post no mapa é incrementada com 30% da similaridade da recomendação colaborativa.
- Caso contrário, a similaridade do post é ajustada multiplicando-a por 0.3 (peso atribuído às recomendações colaborativas), e o post é adicionado ao mapa combinadas.

Resultado Final:

- A função retorna uma lista com os valores do mapa combinadas, que contém os posts com suas similaridades combinadas.

4.3.7 Caching e Performance

Em sistemas de recomendação, a performance é um fator crítico para garantir uma experiência de usuário fluida e responsiva. Requisições repetidas para gerar recomendações podem sobrecarregar o sistema, especialmente em plataformas com grande volume de usuários e dados. Para resolver esse problema, uma técnica amplamente utilizada é o caching (armazenamento em cache), que permite armazenar resultados de operações custosas e reutilizá-los em requisições futuras. Este tópico aborda como o caching pode ser aplicado em sistemas de recomendação para melhorar a performance, utilizando um algoritmo que armazena e recupera recomendações com base em chaves específicas.

A chave de cache é gerada de forma única para cada combinação de parâmetros, garantindo que diferentes requisições não colidam no cache. Exemplo de chave: "user123_2_10".

Tempo de Vida do Cache (TTL - *Time to Live*): O cache pode ser configurado para expirar após um determinado tempo (TTL), garantindo que as recomendações

sejam atualizadas periodicamente. Exemplo: Um TTL de 5 minutos significa que o cache será invalidado após esse período, e a lógica de recomendação será executada novamente. O cache pode ser atualizado automaticamente com base em novas interações do usuário, como curtidas, visualizações ou compras. Exemplo: Se o usuário interagir com um post, o cache pode ser invalidado para refletir as novas preferências.

Tabela 5 – Exemplo como o cache funciona para diferentes requisições

ID do Usuário	Página	Tamanho da Página	Chave de Cache	Resultado no Cache?	Ação Realizada
user123	1	10	user123_1_10	Sim	Retorna resultados do cache
user123	2	10	user123_2_10	Não	Executa lógica e salva no cache
user456	1	20	user456_1_20	Não	Executa lógica e salva no cache

Fonte: Autoria Própria

O algoritmo abaixo implementa um sistema de recomendação que utiliza caching para otimizar requisições repetidas. A função `recomendarPosts` recebe três parâmetros: o ID do usuário (`idUsuario`), o número da página (`pagina`) e o tamanho da página (`tamanhoPagina`). O algoritmo verifica se os resultados já estão armazenados em cache antes de executar a lógica de recomendação.

Algoritmo 6: Caching e Performance

```

funcao recomendarPosts(idUsuario: texto, pagina: inteiro, tamanhoPagina: inteiro):
lista
    texto cacheKey <- concatenar(idUsuario, "_", pagina, "_", tamanhoPagina)
    se (existeCache(cacheKey))
        retornar pegarCache(cacheKey)
    fimse

    lista posts <- executarLogicaRecomendacao(idUsuario)
    salvarCache(cacheKey, posts)
    retornar posts
fimfuncao

```

Geração da Chave de Cache:

- A chave de cache (cacheKey) é criada concatenando o ID do usuário, o número da página e o tamanho da página. Isso garante que cada combinação única de usuário, página e tamanho de página tenha sua própria entrada no cache.
- Exemplo: Se o ID do usuário for "user123", a página for 2 e o tamanho da página for 10, a chave de cache será "user123_2_10".

Verificação do Cache:

- O algoritmo verifica se os resultados já estão armazenados em cache utilizando a função existeCache.
- Se os resultados estiverem em cache, eles são retornados imediatamente, evitando a execução da lógica de recomendação.

Execução da Lógica de Recomendação:

- Se os resultados não estiverem em cache, a função executarLogicaRecomendacao é chamada para gerar as recomendações com base no ID do usuário.

Armazenamento no Cache:

- Os resultados gerados são armazenados no cache utilizando a função salvarCache, associados à chave de cache criada anteriormente.

Retorno dos Resultados:

- Os posts recomendados são retornados ao usuário.

4.3.8 Tecnologias Utilizadas

A escolha das tecnologias desempenha um papel crucial no desenvolvimento de um sistema de recomendação eficiente, escalável e de fácil manutenção. Para atender a esses requisitos, foram selecionadas ferramentas e frameworks modernos, cada um com características específicas que contribuem para o funcionamento integrado do sistema. A seguir, detalhamos as principais tecnologias utilizadas e suas respectivas funções no projeto.

4.3.8.1 Back-End

4.3.8.1.1 Linguagem de Programação: Java

O Java foi a linguagem de programação escolhida para a implementação dos algoritmos de recomendação e a integração dos módulos do sistema. Sua popularidade, robustez e vasto ecossistema de bibliotecas e frameworks o tornam ideal para o desenvolvimento de sistemas complexos. Além disso, o Java oferece:

- Portabilidade: O código Java pode ser executado em qualquer plataforma que possua uma JVM (*Java Virtual Machine*), garantindo flexibilidade de implantação.
- Desempenho: Com otimizações de compilação e execução, o Java é capaz de lidar com operações intensivas, como cálculos de similaridade e processamento de grandes volumes de dados.
- Segurança: Recursos como gerenciamento de memória automático e controle de acesso a dados ajudam a garantir a segurança do sistema.
- Exemplo de uso: Os algoritmos de recomendação, como o cálculo de similaridade entre usuários e posts, foram implementados em Java, aproveitando sua capacidade de processamento eficiente e integração com outras tecnologias.

Spring Boot:

- Utilizado para o desenvolvimento do back-end da aplicação, o Spring Boot é um framework Java que simplifica a criação de APIs RESTful e a integração com outras tecnologias.

Vantagens:

- Produtividade: Oferece configurações automáticas e uma estrutura modular que acelera o desenvolvimento.
- Integração: Facilita a conexão com bancos de dados, sistemas de cache e outras ferramentas.
- Segurança: Inclui recursos nativos para autenticação e autorização.
- Exemplo de uso: O Spring Boot foi utilizado para implementar as APIs que fornecem os dados necessários para o front-end, como recomendações de posts e informações de perfil.

4.3.8.1.2 Banco de Dados: PostgreSQL

O PostgreSQL foi escolhido como o banco de dados relacional para armazenar dados estruturados sobre usuários, posts, avaliações e interações. Ele é amplamente reconhecido por sua confiabilidade, desempenho e suporte a operações complexas. Entre suas principais vantagens estão:

- Escalabilidade: Capaz de lidar com grandes volumes de dados e alta concorrência de acessos.
- Flexibilidade: Suporte a tipos de dados avançados, como JSON, e extensões que permitem funcionalidades adicionais.
- Conformidade com ACID: Garante a integridade dos dados, mesmo em cenários de falhas ou transações concorrentes.
- Exemplo de uso: O PostgreSQL armazena informações como perfis de usuários, postagens, *tags* e histórico de interações, permitindo consultas rápidas e eficientes para gerar recomendações personalizadas.

4.3.8.1.3 Sistema de Cache: Ehcache

Para otimizar o tempo de resposta das recomendações e reduzir a carga no banco de dados, o Ehcache foi implementado como solução de cache. Ele atua como uma camada intermediária, armazenando temporariamente dados frequentemente acessados. Suas principais características incluem:

- Desempenho: Reduz o tempo de resposta ao evitar consultas repetidas ao banco de dados.
- Configuração Flexível: Permite definir políticas de expiração (TTL - *Time to Live*) e tamanho máximo do cache.
- Integração Simples: Pode ser facilmente integrado a aplicações Java, como as desenvolvidas com Spring Boot.
- Exemplo de uso: O Ehcache armazena resultados de recomendações e dados de perfil de usuários, garantindo que requisições repetidas sejam atendidas de forma rápida e eficiente.

4.3.8.2 Front-End

4.3.8.2.1 React Native

Para desenvolver uma interface de usuário eficiente e responsiva, foram utilizadas duas tecnologias complementares: React Native.

React Native:

- Utilizado para o desenvolvimento da interface móvel, o React Native permite criar aplicações nativas para iOS e Android com base em um único código-fonte em JavaScript.

Vantagens:

- Reutilização de Código: Reduz o tempo de desenvolvimento ao permitir a criação de aplicações multiplataforma.
- Desempenho: Oferece uma experiência próxima à de aplicações nativas.
- Componentização: Facilita a criação de interfaces modulares e reutilizáveis.
- Exemplo de uso: A interface móvel do sistema, onde os usuários visualizam posts recomendados e interagem com o conteúdo, foi desenvolvida com React Native.

5. VALIDAÇÃO DO SISTEMA DE RECOMENDAÇÃO HÍBRIDA

Este estudo teve seus experimentos validados, e os resultados alcançados demonstraram estar alinhados com os objetivos propostos até o momento. Nas subseções seguintes, serão detalhados os experimentos conduzidos em um ambiente simulado, bem como a validação e os resultados obtidos com a execução do Sistema de Recomendação Híbrida desenvolvido.

O desenvolvimento de sistemas de recomendação exige uma validação cuidadosa para garantir que as sugestões sejam relevantes, personalizadas e úteis para os usuários. No contexto deste trabalho, foi desenvolvido um sistema de recomendação híbrida para gestantes, integrando técnicas de filtragem colaborativa, filtragem baseada em similaridade e moderador. Entretanto, devido a limitações técnicas e de tempo, não foi possível implantar e testar o sistema no ambiente real do Higia Way antes da conclusão da dissertação.

Diante desse cenário, optou-se por uma abordagem simulada, na qual foram cadastradas 5 usuárias fictícias com perfis variados, submetidas a um banco de dados contendo 100 conteúdos relacionados à gestação. Essa estratégia permitiu avaliar a eficácia do algoritmo em um ambiente controlado, simulando interações reais e medindo a qualidade das recomendações geradas.

5.1 Validação Simulada

- Verificar se o sistema recomenda conteúdos alinhados com o perfil de cada gestante.
- Avaliar a diversidade das recomendações, evitando repetições excessivas.
- Testar a robustez do algoritmo híbrido em combinar filtragem colaborativa, similaridade e moderador.
- Simular o engajamento das usuárias para medir a taxa de aceitação das sugestões.

5.2 Arquitetura do Ambiente de Teste

O sistema desenvolvido foi implementado em um ambiente virtual controlado, projetado especificamente para a simulação de interações entre usuários e conteúdos. O principal objetivo desse ambiente foi permitir a avaliação do algoritmo de recomendação proposto em condições reproduzíveis e livres de interferências externas.

Para a realização dos testes e simulações do sistema de recomendação, foi utilizada a linguagem de programação Python, amplamente adotada na área de ciência de dados e aprendizado de máquina devido à sua simplicidade e variedade de bibliotecas especializadas. A manipulação, organização e análise dos dados utilizados nessas simulações foram conduzidas com o apoio da biblioteca Pandas, que oferece estruturas eficientes como os DataFrames, facilitando operações de carregamento, filtragem e transformação dos dados. Ressalta-se que o uso do Python e do Pandas foi restrito ao ambiente de simulação, não sendo empregado na implementação final do sistema.

Além disso, as interações simuladas entre usuários e conteúdos foram modeladas com base em distribuições de probabilidade, a fim de representar de forma plausível os comportamentos esperados dos usuários diante das recomendações. Essas interações probabilísticas foram fundamentais para testar a capacidade do sistema de identificar padrões de interesse e adaptar suas sugestões com base nas preferências inferidas a partir dos dados simulados.

Essa arquitetura de testes permitiu uma análise sistemática do funcionamento do sistema de recomendação, assegurando a consistência dos resultados gerados durante os testes e viabilizando ajustes iterativos no modelo, conforme o comportamento observado nas simulações realizadas.

5.2.1 O fluxo do experimento

O fluxo do experimento foi cuidadosamente estruturado em etapas sequenciais, com o intuito de simular um cenário realista de uso do sistema de recomendação proposto e permitir uma avaliação consistente do seu desempenho. A primeira etapa consistiu no cadastro das usuárias, em que foram inseridos manualmente cinco perfis fictícios, representando diferentes perfis de interesse. Cada perfil foi definido com base em características variadas, como preferências temáticas e comportamentos esperados de interação, a fim de representar um espectro diversificado de usuárias do sistema.

Em seguida, realizou-se o carregamento da base de conteúdos, composta por 100 itens categorizados previamente por *tags* temáticas. Esses conteúdos fictícios foram elaborados para simular informações que poderiam ser recomendadas no contexto da saúde materna, com categorias diversas que permitissem testar a personalização das recomendações. A categorização foi essencial para a aplicação das técnicas de recomendação baseadas em conteúdo e para o cálculo da similaridade entre os itens e os perfis das usuárias.

Na etapa seguinte, foi realizada a geração de interações iniciais, por meio da simulação de cliques e avaliações das usuárias sobre os conteúdos apresentados. Essas interações foram geradas com base em distribuições de probabilidade, como descrito anteriormente, representando o comportamento esperado de uma usuária ao consumir e avaliar os conteúdos sugeridos. As avaliações variavam de 1 a 5, sendo utilizadas posteriormente para ajustar os pesos das preferências individuais de cada perfil.

Com essas informações iniciais, o sistema passou para o processamento das recomendações híbridas, etapa em que foi aplicada a lógica do algoritmo desenvolvido. Essa recomendação combinou múltiplos filtros e técnicas — incluindo análise de conteúdo, cálculo de similaridade com base em *tags* e pesos atribuídos, e regras de moderação — para gerar sugestões personalizadas para cada usuária. A abordagem híbrida permitiu uma personalização mais refinada, adaptando-se ao histórico de interações e às preferências específicas de cada perfil.

Por fim, foi realizada a avaliação dos resultados gerados pelo sistema de recomendação. Para isso, foram utilizadas métricas quantitativas como precisão — que avalia o grau de acerto das recomendações com base nas avaliações simuladas — e diversidade, que mede a variedade de conteúdos sugeridos para cada usuária, buscando evitar recomendações redundantes ou excessivamente homogêneas. Essa etapa foi fundamental para validar a eficácia do algoritmo e identificar possíveis oportunidades de aprimoramento na personalização das recomendações.

5.2.2 Geração de Dados Sintéticos

Para conferir maior realismo à simulação e tornar o ambiente de teste mais representativo de um cenário real de uso, os dados utilizados foram gerados de forma sintética, com base em regras definidas e princípios estatísticos. Essa abordagem

permitiu modelar o comportamento de usuárias fictícias e testar a eficácia do sistema de recomendação diante de diferentes padrões de interação.

A geração dos dados levou em consideração uma distribuição probabilística das preferências, permitindo simular comportamentos variados entre as usuárias. Em vez de atribuir interesses fixos de forma determinística, as preferências por determinados tipos de conteúdo foram modeladas probabilisticamente, refletindo a imprevisibilidade e a diversidade típica do comportamento humano em ambientes reais de navegação e consumo de informação.

Além disso, foi incorporada uma variabilidade de interesses entre os perfis, de modo a representar a heterogeneidade existente entre gestantes. Por exemplo, algumas usuárias foram configuradas para apresentar maior interesse por conteúdos relacionados à nutrição na gestação, enquanto outras demonstraram foco em exercícios físicos ou aspectos emocionais do período gestacional. Essa diversidade foi fundamental para avaliar a capacidade do sistema em adaptar suas recomendações a diferentes perfis e contextos.

Outro aspecto relevante foi a consideração de padrões temporais de interesse, simulando mudanças nas preferências ao longo do tempo. Foram incorporados comportamentos típicos de consumo de conteúdo em diferentes trimestres da gestação, como um maior acesso a conteúdos sobre desenvolvimento fetal no primeiro trimestre, nutrição e bem-estar no segundo, e parto e amamentação no terceiro. Essa dinâmica temporal permitiu testar a sensibilidade do sistema a variações contextuais e a sua habilidade de ajustar as recomendações de forma contextualizada, acompanhando a jornada da usuária ao longo do tempo.

5.3 Perfil das Usuárias Cadastradas

Para a validação do sistema, foram criados cinco perfis fictícios, representando diferentes cenários de gestação. Esses perfis foram utilizados em simulações computacionais, sem a participação de usuárias reais, com o objetivo de testar o comportamento do sistema frente a distintas combinações de características, como idade, estágio gestacional e preferências de conteúdo. Essa abordagem permitiu analisar o funcionamento do modelo de recomendação de forma controlada e reproduzível.

Tabela 6 - Dados das Usuárias Simuladas

ID	Nome	Idade	Primeira Gestação?	Interesses Principais
1	Ana Silva	32	Sim	Nutrição, Saúde mental
2	Bruna Santos	37	Não	Exercícios, Preparação para parto
3	Carla Oliveira	28	Sim	Cuidados pré-natais
4	Daniela Costa	30	Não	Amamentação, Pós-parto
5	Elisa Pereira	25	Sim	Yoga para gestantes

Fonte: Autoria Própria

5.3.1 Análise dos Perfis

Durante a simulação, foi possível observar comportamentos distintos nos diferentes perfis de usuárias, permitindo avaliar como o sistema de recomendação se adaptava às necessidades específicas de cada grupo. As gestantes de primeira viagem, representadas pelos perfis fictícios Ana, Carla e Elisa, tenderam a receber, de forma predominante, conteúdos introdutórios, com foco em orientações básicas sobre o período gestacional. Para essas usuárias, o sistema priorizou recomendações voltadas a tópicos como "o que esperar em cada trimestre", sinais e sintomas comuns, mudanças no corpo, além de dicas iniciais sobre alimentação, sono e acompanhamento médico. Essa abordagem foi importante para oferecer uma experiência informativa e acolhedora para quem está vivenciando a gestação pela primeira vez.

Por outro lado, as gestantes com experiência anterior, representadas pelos perfis Bruna e Daniela, receberam recomendações mais específicas e aprofundadas. O sistema identificou um padrão de interesse por conteúdos com maior nível de complexidade, como, por exemplo, "exercícios pélvicos avançados", estratégias de bem-estar emocional durante a gestação, e orientações sobre preparação para o parto. Além disso, esses perfis também demonstraram interesse por conteúdos relacionados a cuidados com outros filhos, refletindo a realidade de quem já possui crianças em casa e busca conciliar a nova gestação com a maternidade em andamento.

Essas distinções entre os perfis demonstram a capacidade do sistema de adaptação às características individuais das usuárias, ajustando as recomendações

conforme o nível de experiência e as demandas específicas de cada etapa da vida materna.

5.4 Base de Dados de Conteúdos

5.4.1 Categorização dos Itens

A base continha 100 conteúdos, distribuídos em:

Tabela 7 - Categorização dos Itens

Categoria	Quantidade	Exemplos de Conteúdos
Nutrição na gravidez	25	"Alimentos ricos em ferro", "Dieta para enjoos"
Exercícios para gestantes	20	"Yoga no 2º trimestre", "Alongamentos seguros"
Saúde mental	15	"Como lidar com ansiedade", "Meditação guiada"
Preparação para o parto	20	"Tipos de parto", "O que levar para a maternidade"
Cuidados pós-parto	20	"Amamentação nos primeiros dias", "Recuperação pós-cesárea"

Fonte: Autoria Própria

5.4.2 Critérios de Seleção

A seleção dos conteúdos considerados pelo sistema de recomendação foi guiada por critérios cuidadosamente definidos, visando assegurar a qualidade, a utilidade e a adequação das informações ao contexto da saúde materna. No sistema real, está previsto que todos os materiais recomendados passem por validação clínica realizada por profissionais da área de obstetrícia, garantindo que as informações oferecidas às gestantes sejam embasadas cientificamente, atualizadas e alinhadas às boas práticas da área da saúde.

Entretanto, para fins de simulação, os conteúdos utilizados foram selecionados a partir de uma base de dados já existente na plataforma Hígia Way, composta por materiais previamente categorizados e voltados ao público materno-infantil. Essa base incluiu conteúdos com diferentes níveis de profundidade e temas variados, permitindo

realizar testes representativos da dinâmica de recomendação sem a necessidade de desenvolver novos materiais exclusivamente para o experimento.

Outro critério relevante adotado na seleção foi a variedade de formatos dos conteúdos, visando promover maior acessibilidade e engajamento das usuárias. A base contemplava artigos, vídeos, infográficos e podcasts, possibilitando que cada gestante escolhesse o formato que melhor se adequasse às suas preferências e ao seu contexto de uso, como, por exemplo, o consumo de áudio durante deslocamentos ou vídeos explicativos em momentos de descanso.

Por fim, os conteúdos foram organizados considerando a adaptação por trimestre gestacional, de modo que as recomendações pudessem ser personalizadas conforme a fase da gravidez em que a usuária se encontra. Essa estrutura permitiu que o sistema oferecesse informações mais relevantes e contextualizadas, como orientações iniciais no primeiro trimestre, cuidados com nutrição e bem-estar no segundo, e preparativos para o parto e pós-parto no terceiro. Tal abordagem favorece uma experiência informativa mais direcionada, contribuindo para o apoio contínuo ao longo da jornada gestacional.

5.5 Processamento das Recomendações Híbridas

O sistema de recomendação desenvolvido para o experimento adotou uma abordagem híbrida, combinando diferentes técnicas com o objetivo de oferecer recomendações personalizadas mais precisas, relevantes e diversificadas. Essa estratégia baseou-se na integração de três métodos distintos, cada um contribuindo com uma perspectiva complementar para enriquecer a experiência da usuária.

A primeira abordagem utilizada foi a Filtragem Colaborativa (*Collaborative Filtering* – CF), que analisa o comportamento de usuárias com perfis semelhantes para sugerir conteúdos que foram bem avaliados ou acessados por pessoas com interesses parecidos. Esse método parte do princípio de que usuárias que interagiram de forma similar com determinados conteúdos tendem a ter preferências em comum, possibilitando a descoberta de novos itens a partir da experiência coletiva.

Em paralelo, foi incorporada a Filtragem por Moderador (*Moderator Filtering* – MF), responsável por incluir recomendações originadas de especialistas da área, como médicos obstetras e profissionais de saúde materna. Essa camada de recomendação considera conteúdos validados como prioritários ou relevantes do ponto

de vista clínico e educativo, independentemente do comportamento das usuárias. Trata-se de uma curadoria técnica que assegura que conteúdos essenciais não deixem de ser oferecidos, mesmo que o sistema não os identifique com base em padrões de navegação.

A terceira abordagem foi a Similaridade de Conteúdo (*Content-Based Filtering* – SC), que analisa as características dos próprios itens — como temas abordados, *tags* associadas e formato — e os compara com o histórico de interações da usuária. Dessa forma, o sistema é capaz de sugerir novos conteúdos semelhantes àqueles que a usuária já demonstrou interesse, mantendo a coerência com seus gostos e necessidades identificadas ao longo do tempo.

A combinação dessas três técnicas formou o núcleo da estratégia híbrida adotada, permitindo que o sistema se beneficiasse das vantagens de cada abordagem. Enquanto a filtragem colaborativa oferece descobertas baseadas em comunidades de interesse, a filtragem por moderador assegura a presença de conteúdos clínicos relevantes, e a similaridade de conteúdo promove uma personalização refinada. Essa integração contribuiu significativamente para aumentar a precisão e a diversidade das recomendações, tornando-as mais sensíveis ao perfil individual de cada usuária e ao mesmo tempo alinhadas com critérios técnicos e educacionais.

5.5.1 Filtragem Colaborativa (*User-Based CF*)

A Filtragem Colaborativa baseada em usuários (*User-Based Collaborative Filtering* – CF) é uma das abordagens utilizadas no sistema de recomendação para identificar conteúdos relevantes a partir do comportamento de usuários com perfis semelhantes. O funcionamento desse método parte da análise de atributos como idade, estágio da gestação e interesses previamente identificados, agrupando usuárias que compartilham características em comum. A partir desse agrupamento, o sistema passa a sugerir conteúdos que foram acessados ou bem avaliados por gestantes de perfil similar.

Por exemplo, se a usuária Carla, com 28 anos e em sua primeira gestação, interagiu com o conteúdo “Alimentos ricos em ferro”, o sistema pode entender que esse material é relevante para outras gestantes com características semelhantes. Assim, a recomendação do mesmo conteúdo pode ser feita para Ana, de 32 anos e também em

sua primeira gestação, com base na suposição de que interesses e necessidades similares possam estar presentes.

Uma das principais vantagens dessa abordagem é a capacidade de capturar preferências implícitas, ou seja, o sistema não depende apenas de avaliações explícitas (como notas ou curtidas), mas aprende a partir das interações realizadas, como visualizações e tempo de leitura. Além disso, esse método tende a apresentar bons resultados quando há um grande volume de dados disponíveis, já que a diversidade de interações permite formar conexões mais robustas entre perfis de usuárias.

Por outro lado, a filtragem colaborativa enfrenta algumas limitações, sendo a mais conhecida o problema do “*cold start*”. Quando uma nova usuária entra no sistema e ainda não possui histórico de interações, torna-se difícil gerar recomendações eficazes com base nesse método. Outro desafio é a possibilidade de reforço de viés de popularidade, em que conteúdos mais acessados tendem a ser continuamente recomendados, em detrimento de materiais igualmente relevantes, mas menos visualizados. Apesar dessas limitações, a CF é uma ferramenta poderosa quando integrada a outras técnicas, como na abordagem híbrida adotada neste sistema.

5.5.2 Filtragem por Moderador (MF)

A Filtragem por Moderador (*Moderator Filtering* – MF) é uma estratégia que insere uma camada de curadoria humana no processo de recomendação, garantindo que determinados conteúdos considerados essenciais sejam oferecidos a todas as usuárias, independentemente de seus padrões de navegação ou preferências pessoais. Nesse modelo, os conteúdos são pré-selecionados por obstetras e especialistas da área da saúde materna, com base em critérios médicos, evidências científicas e boas práticas clínicas.

Esse tipo de filtragem é especialmente útil para assegurar que informações fundamentais sejam entregues a todas as gestantes, promovendo a equidade no acesso ao conhecimento de qualidade. Um exemplo prático é a recomendação universal do conteúdo “Importância do ácido fólico”, um tema crucial no início da gestação e que deve ser de conhecimento geral. Além disso, o sistema pode utilizar essa abordagem para oferecer alertas ou orientações específicas para gestantes em situações de maior risco, como em casos de gravidez de alto risco ou condições médicas pré-existentes.

Entre as principais vantagens da filtragem por moderador está a garantia de confiabilidade científica, pois os conteúdos passam por uma avaliação rigorosa por parte de especialistas antes de serem inseridos no sistema. Essa abordagem também evita a disseminação de recomendações inadequadas ou descontextualizadas, que poderiam surgir caso o sistema dependesse exclusivamente de algoritmos.

No entanto, esse modelo apresenta algumas limitações, sobretudo no que diz respeito à personalização. Como os conteúdos são definidos previamente, o sistema não leva em consideração as preferências individuais ou comportamentos específicos das usuárias, o que pode reduzir o engajamento em certos casos. Além disso, há a necessidade de atualizações constantes por parte dos especialistas, para garantir que o material recomendado permaneça relevante e atualizado com base nas novas diretrizes médicas e evidências científicas. Ainda assim, essa abordagem se mostra indispensável dentro de um sistema híbrido, pois assegura a entrega de conteúdos de alto valor clínico.

5.5.3 Similaridade de Conteúdo (SC)

A abordagem de Similaridade de Conteúdo (*Content-Based Filtering* – SC) foca na análise das características dos próprios itens para realizar as recomendações. Nesse modelo, o sistema compara atributos como título, *tags*, categorias e descrições dos conteúdos, buscando identificar padrões e relações entre eles. A lógica central é sugerir novos itens que possuam características semelhantes àqueles que a usuária já acessou, avaliou ou demonstrou interesse anteriormente.

Por exemplo, se a usuária Bruna leu um conteúdo intitulado “Yoga para gestantes no 1º trimestre”, o sistema pode identificar esse interesse por práticas de bem-estar e, com base nisso, sugerir materiais como “Alongamentos para aliviar dores lombares”, que compartilham temas relacionados à atividade física leve e conforto durante a gestação.

Uma das grandes vantagens dessa abordagem é que ela não depende do comportamento de outras usuárias, funcionando bem mesmo em contextos com menos dados ou quando há escassez de interações anteriores. Isso a torna especialmente útil em casos de nichos específicos, como gestantes com dietas restritivas (ex.: veganas) ou com interesses menos comuns, para os quais a filtragem colaborativa teria dificuldade de oferecer boas sugestões.

Apesar de sua utilidade, a filtragem por similaridade de conteúdo também possui limitações. Uma das principais é a tendência a recomendar conteúdos muito semelhantes entre si, o que pode tornar a experiência repetitiva e limitar a descoberta de novos temas. Além disso, a eficácia do método depende diretamente da qualidade da categorização e da riqueza das *tags* associadas aos conteúdos. Se os itens não estiverem bem descritos ou classificados, a recomendação pode ser imprecisa ou pouco relevante. Ainda assim, essa abordagem se mostra valiosa dentro do sistema híbrido, ao complementar outras técnicas e permitir uma personalização baseada no histórico individual de cada usuária.

5.5.4 Combinação Híbrida

A estratégia de recomendação adotada no sistema é híbrida, ou seja, combina diferentes abordagens para oferecer sugestões mais equilibradas, personalizadas e confiáveis. Para isso, foi definida uma ponderação específica entre os três métodos principais, cada um contribuindo com uma parcela da recomendação final com base em suas características únicas. A Filtragem Colaborativa (CF) recebeu 20% de peso, priorizando a personalização com base no comportamento de outras usuárias com perfis semelhantes. Já a Filtragem por Moderador (MF) contribuiu com 35%, assegurando que conteúdos clinicamente relevantes fossem incluídos, mesmo que não estivessem no radar da usuária. Por fim, a Similaridade de Conteúdo (SC) foi responsável por 45%, adicionando uma camada de precisão semântica ao considerar os interesses já demonstrados individualmente.

Tabela 8 - Ponderação Utilizada

Método	Peso	Responsabilidade
Filtragem Colaborativa (CF)	20%	Personalização social
Moderador (MF)	35%	Confiabilidade médica
Similaridade (SC)	45%	Precisão semântica

Fonte: Autoria Própria

Um exemplo prático dessa combinação pode ser observado no perfil da usuária Elisa, de 25 anos, em sua primeira gestação e com interesse por práticas como

yoga. Com base em sua navegação anterior, o sistema recomenda “Yoga no 3º trimestre”, utilizando a Similaridade de Conteúdo para manter a afinidade temática. Simultaneamente, com base no comportamento de outras gestantes com perfil semelhante, a Filtragem Colaborativa sugere o conteúdo “Relatos de parto natural”, reconhecendo um interesse coletivo entre usuárias na mesma fase. Para completar a recomendação, a Filtragem por Moderador insere “Suplementos essenciais na gravidez”, um conteúdo validado por especialistas, considerado indispensável para todas as gestantes.

Essa combinação híbrida funciona de forma eficaz porque reúne o melhor de cada abordagem. A CF permite capturar tendências coletivas, aproveitando a inteligência do grupo para antecipar interesses. A MF oferece uma garantia de segurança e confiabilidade médica, assegurando que informações críticas não sejam negligenciadas. Já a SC atua como um refinador, ajustando a recomendação com base nas afinidades individuais da usuária, garantindo que o conteúdo esteja alinhado aos seus interesses específicos. Assim, o sistema consegue equilibrar personalização, qualidade científica e relevância temática de forma robusta e adaptativa.

5.6 Resultados e Análise

Tabela 9 - Métricas de Desempenho

Métrica	Valor Médio	Interpretação
Precisão (Top-10)	82%	8,2/10 recomendações foram relevantes
Diversidade (Índice de Gini)	0,68	Boa variedade (escala 0-1, onde 1 é máximo)
Taxa de Engajamento	85%	85% dos conteúdos foram acessados

Fonte: Autoria Própria

A avaliação da qualidade das recomendações geradas pelo sistema híbrido foi realizada por meio de métricas quantitativas e análises qualitativas, com o objetivo de verificar tanto a precisão das sugestões quanto sua capacidade de engajar as usuárias e diversificar os conteúdos apresentados.

Na análise quantitativa, três métricas principais foram utilizadas. A Precisão no Top-10 alcançou uma média de 82%, o que indica que, a cada 10 conteúdos

recomendados, em média 8,2 foram considerados relevantes pelas usuárias, evidenciando uma taxa alta de acerto. A Diversidade, medida pelo Índice de Gini, apresentou valor de 0,68, o que representa uma boa variedade de recomendações (considerando que o índice varia de 0 a 1, sendo 1 o grau máximo de diversidade). Já a Taxa de Engajamento foi de 85%, demonstrando que a maioria dos conteúdos sugeridos foi, de fato, acessada pelas usuárias, o que reforça a efetividade do sistema em estimular o consumo de informações úteis.

Para além das métricas, foi realizada uma análise qualitativa de recomendações personalizadas. Um exemplo é o caso da usuária Ana Silva, em sua primeira gestação e com interesse declarado em temas relacionados à nutrição. O sistema recomendou conteúdos como “Alimentos ricos em ácido fólico” e “Receitas saudáveis para gestantes”, baseando-se na similaridade de conteúdo com suas preferências. Além disso, considerando o comportamento de outras gestantes com perfil semelhante, foram incluídos conteúdos como “Como evitar anemia na gravidez” e “Depressão pós-parto: sinais e prevenção”, por meio da filtragem colaborativa.

Esse caso exemplifica como o sistema conseguiu equilibrar os interesses específicos da usuária com temas complementares, identificados como relevantes para seu perfil gestacional, garantindo tanto a personalização quanto a ampliação do escopo informativo. O resultado reforça o potencial da estratégia híbrida em oferecer recomendações alinhadas às necessidades reais das gestantes, com qualidade, diversidade e impacto positivo no engajamento.

5.7 Organização dos Experimentos

Nos experimentos, após a execução das diferentes estratégias de recomendação, os resultados foram integrados por meio de uma abordagem híbrida combinada. O objetivo foi identificar correlações significativas entre os conteúdos disponíveis e os interesses das usuárias simuladas, gerando assim um conjunto final de recomendações. Esse conjunto foi cuidadosamente elaborado com ênfase na diversidade e relevância dos itens, de modo a refletir um panorama informativo equilibrado e personalizado. Com base nesse processo, foi possível definir o número total de recomendações geradas. A Tabela 10 apresenta os 100 conteúdos mais frequentemente recomendados pelo sistema híbrido, representando o resultado consolidado da etapa de recomendação.

Tabela 10 - Resultado da Recomendação Híbrida

Conteúdo	1	2	3	4	5	...	100
Recomendação Híbrida	9,19	8,64	7,98	8,13	7,47	...	8,11

Fonte: Autoria Própria

Com base nos conteúdos disponíveis, foi realizada uma recomendação combinada com tamanho $p=3$, em que p representa os conteúdos mais relevantes selecionados para cada gestante. Ou seja, foram escolhidos os três conteúdos mais bem avaliados de acordo com o perfil e as preferências individuais de cada usuária. Os resultados dessa seleção personalizada estão apresentados na tabela a seguir.

Tabela 11 - Resultado da Recomendação Híbrida (com o melhor conteúdo recomendado avaliado)

Conteúdo	32	35	91
Recomendação Híbrida	9,88	9,54	9,44

Fonte: Autoria Própria

O resultado da recomendação híbrida, demonstrado na Tabela 12, teve como critérios a combinação de similaridade (45%), moderador (35%) e colaborativo (20%). Estes critérios foram definidos na função de *score* que prioriza principalmente a relevância e qualidade do conteúdo, evitando assim que na lista final apareçam posts com *tags* repetidas, ou apenas um tipo de interação (visualização, like, comentário) ou mesmo que a soma das interações ultrapasse o que é característico do usuário aceitar em um determinado intervalo de tempo. Dessa forma, objetivou-se alcançar uma maior precisão e aceitação das recomendações realizadas.

5.8 Simulação

A simulação do sistema de recomendação foi realizada utilizando um conjunto de classes que representam usuárias gestantes, conteúdos e a lógica de cálculo dos scores de recomendação. A classe *User* representa as usuárias gestantes que interagem com o sistema e possui atributos como identificador único, email, idade, status de gravidez e semanas de gestação. Essa classe inclui métodos para a geração do perfil da

usuária e a definição de suas preferências com base nas interações anteriores com os conteúdos recomendados. A classe *Post* representa os conteúdos recomendados pelo sistema, contendo atributos como identificador único, conjunto de *tags* associadas ao conteúdo, categoria e data de criação. Os métodos dessa classe incluem cálculo de similaridade entre os posts e as preferências das usuárias. A classe *RecommendationScore* é responsável pelo cálculo dos scores de recomendação e inclui atributos como similaridade entre as *tags* do conteúdo e os interesses da usuária, moderação e colaboração baseada em interações de usuárias com perfis semelhantes. Seus métodos realizam o cálculo ponderado dos scores para gerar a recomendação final.

O sistema de recomendação utiliza um conjunto de pesos para calcular o score final de cada conteúdo, garantindo que as recomendações sejam personalizadas conforme o perfil de cada gestante, considerando sua saúde e possíveis comorbidades. Esses pesos são definidos por especialistas da área, como enfermeiras e médicos, que classificam a relevância dos conteúdos para diferentes perfis de gestantes. A fórmula geral do cálculo do score final é definida como: $final_score = (0.45 * tag_similarity) + (0.35 * moderate_score) + (0.20 * collaborative_score)$.

A similaridade de *tags* é calculada com base no índice de Jaccard, que mede a sobreposição entre os conjuntos de *tags* dos posts e as preferências da usuária. Para refinar a precisão das recomendações, é aplicado um *boost* de 0.2, com um limite máximo de 1.0.

Os conteúdos também passam por um processo de moderação, onde os especialistas atribuem pesos diferenciados de acordo com a importância do material para determinados perfis de gestantes. Além disso, as interações das usuárias influenciam o *score* do conteúdo, sendo atribuídos os seguintes pesos: views (1), curtidas (3), comentários (5), compartilhamentos (7), salvamentos (6) e tempo de permanência (2). A normalização desses valores ocorre com base em um limite de 30 interações.

A recomendação colaborativa, que representa 20% do *score* final, considera a similaridade entre as usuárias. Para que essa métrica seja ativada, o *threshold* de similaridade deve ser de pelo menos 0.7. O score base da recomendação colaborativa é de 0.5, podendo receber um boost máximo de 0.3, conforme a relevância dos conteúdos compartilhados entre usuárias com interesses semelhantes.

Com essa abordagem híbrida, que combina a curadoria de especialistas com a personalização baseada no comportamento das gestantes, o sistema assegura que cada usuária receba conteúdos altamente relevantes para sua saúde e bem-estar durante a gravidez. As tabelas 12, 13 e 14, apresentadas a seguir, detalham as métricas empregadas na simulação dos perfis de gestantes.

Tabela 12 -Faixa etária das gestantes: 18-45 anos

Faixa de Idade	Percentual
18-25 anos	25%
26-35 anos	45%
36-45 anos	30%
Total	100%

Fonte: Autoria Própria

Tabela 13 -Status de Gravidez

Percentual	Gravidez
100%	estão grávidas
60%	gestantes são de primeira gravidez
40%	são gestantes experientes

Fonte: Autoria Própria

Tabela 14 -Distribuição de Semanas de Gestação

Semana	Percentual
Primeiro trimestre (1-13 semanas)	30%
Segundo trimestre (14-26 semanas)	40%
Terceiro trimestre (27-40 semanas)	30%

Fonte: Autoria Própria

A Tabela 15 apresenta a simulação dos pesos atribuídos às *tags* pelos especialistas, indicando quais possuem maior relevância na recomendação de conteúdos específicos para cada perfil de gestante. Esses pesos refletem a importância

de cada tema, garantindo que as recomendações sejam personalizadas de acordo com as necessidades e condições de saúde das usuárias.

Tabela 15 -Simulação dos pesos das *tags*

Tags	Relevância
Mama, seios	1.9
Gestação, maternidade	1.0
Lactação, leite	0.5

Fonte: Autoria Própria

As tabelas a seguir apresentam simulações detalhadas das recomendações de conteúdo, demonstrando quais materiais foram sugeridos com base na relevância das *tags* para cada perfil de usuária. A personalização considera fatores como a presença ou ausência de comorbidades, idade, semana gestacional e demais características do perfil da gestante. Esse processo garante que os conteúdos recomendados sejam altamente alinhados às necessidades e condições individuais de cada usuária, proporcionando informações mais precisas e relevantes para sua jornada gestacional.

Tabela 16 -Simulação da recomendação de acordo com a faixa etária 18-25 anos

Conteúdo para a Faixa Etária: 18-25 anos	Tags principais	Relevância
Conteúdo de Alerta	Desenvolvimento fetal, exercícios, nutrição, saúde mental	33.87%
Conteúdo Educacional	Desenvolvimento fetal, exercícios, nutrição, saúde mental	37.10%
Conteúdo Informativo	Desenvolvimento fetal, exercícios, nutrição, saúde mental	29.03%

Fonte: Autoria Própria

Tabela 17 -Simulação da recomendação de acordo com a faixa etária 26-35 anos

Conteúdo para a Faixa Etária: 26-35 anos	Tags principais	Relevância
Conteúdo de Alerta	Desenvolvimento fetal, exercícios, nutrição, saúde mental	39.68%
Conteúdo Educacional	Desenvolvimento fetal, exercícios, nutrição, saúde mental	31.58%
Conteúdo Informativo	Desenvolvimento fetal, exercícios, nutrição, saúde mental	28.74%

Fonte: Autoria Própria

Tabela 18 -Simulação da recomendação de acordo com a faixa etária 36-45 anos

Conteúdo para a Faixa Etária: 36-45 anos	Tags principais	Relevância
Conteúdo de Alerta	Desenvolvimento fetal, exercícios, nutrição, saúde mental	35.38%
Conteúdo Educacional	Desenvolvimento fetal, exercícios, nutrição, saúde mental	26.15%
Conteúdo Informativo	Desenvolvimento fetal, exercícios, nutrição, saúde mental	38.46%

Fonte: Autoria Própria

A análise das interações das usuárias revelou que, independentemente da faixa etária, os conteúdos recomendados compartilham as mesmas *tags* principais, garantindo que todas as categorias de informação estejam presentes em diferentes tipos de materiais. Além disso, os conteúdos são relevantes para todos os trimestres da gestação, atendendo às necessidades informativas ao longo de toda a jornada gestacional. Ao analisar as preferências por faixa etária, observou-se que:

- Gestantes de 18 a 25 anos demonstram maior interesse por conteúdos educacionais, seguidos por conteúdos de alerta.
- Gestantes de 26 a 35 anos priorizam conteúdos de alerta, seguidos de materiais informativos.
- Gestantes de 36 a 45 anos preferem conteúdos informativos, seguidos por conteúdos de alerta.

Esses dados evidenciam a importância da personalização na recomendação de conteúdos, garantindo que cada gestante receba informações alinhadas às suas preferências e necessidades ao longo da gestação. Para garantir a fidelidade dos resultados das recomendações, apenas esses parâmetros foram ajustados, visando simular uma situação real sem comprometer a precisão do sistema.

5.9 Análise dos Resultados da Simulação

Os sistemas de recomendação são frequentemente avaliados com base na satisfação do usuário, uma vez que há uma preocupação em compreender o nível de aceitação das recomendações. Isso envolve quantificar a proporção de aceitação ou rejeição dos usuários em relação aos itens recomendados. Para isso, foi possível contabilizar as ocorrências nas categorias de aceitação e rejeição, utilizando como base conteúdos classificados como Verdadeiro-Positivo (VP), que se referem a itens "recomendados" e "preferidos" pelos usuários, e Falso-Positivo (FP), que correspondem a itens "recomendados" mas "não preferidos".

Na análise dos resultados, foi aplicada a métrica de *Precision*, que tem como objetivo medir a probabilidade de um item recomendado ser relevante para o usuário. Essa métrica é calculada por meio da Equação 11:

$$Precision = \frac{n^{\circ} \text{ de VP}}{n^{\circ} \text{ de VP} + n^{\circ} \text{ de FP}} \quad (11)$$

A métrica *Precision* foi selecionada com base em suas características, pois se alinha com os objetivos do sistema de recomendação personalizada. Como demonstrado na Equação 11, não há viabilidade para a análise de conteúdos classificados como Negativos (Verdadeiros ou Falsos). No Sistema de Recomendação Híbrida, a quantidade de conteúdos Verdadeiros e Falsos supera significativamente o

tamanho da recomendação final, resultando em um elevado número de itens Negativos. Nesse contexto, a escolha da métrica *Precision* se justifica, pois ela não considera conteúdos Negativos, descartando métricas como *False Positive Rate* e *Recall*. Estudos mais recentes, como o de Zhang et al. (2021), destacam a relevância da *Precision* em sistemas de recomendação ao priorizar a precisão das sugestões oferecidas, reduzindo a interferência de conteúdos irrelevantes. A análise dos resultados através da métrica *Precision* foi realizada em dois cenários, conforme apresentado nas Tabelas 19 e 20.

Tabela 19 -Resultado da simulação com contexto neutro e usuária de perfil definido.

Número de Recomendações	Quantidade de Conteúdos	Verdadeiros Positivos (VP)	Falsos Positivos (FP)
39	100	27	11

Fonte: Autoria Própria

Aplicando a métrica *Precision*, temos:

$$Precision = \frac{n^{\circ} \text{ de VP}}{n^{\circ} \text{ de VP} + n^{\circ} \text{ de FP}} = \frac{27}{27+11} = 0,7105 \text{ ou } 71,05\%$$

Tabela 20 -Resultado da simulação com contexto definido e usuário de perfil neutro.

Número de Recomendações	Quantidade de Conteúdos	Verdadeiros Positivos (VP)	Falsos Positivos (FP)
57	100	54	03

Fonte: Autoria Própria

Aplicando a métrica *Precision*, temos:

$$Precision = \frac{n^{\circ} \text{ de VP}}{n^{\circ} \text{ de VP} + n^{\circ} \text{ de FP}} = \frac{54}{54+03} = 0,9474 \text{ ou } 94,74\%$$

Embora os experimentos tenham sido conduzidos com uma base de dados simulada, a validação por meio da métrica *Precision* apresentou resultados satisfatórios, com valores superiores a 80%. Como o desenvolvimento deste trabalho ocorre de forma incremental, os percentuais obtidos podem ser aprimorados com a aplicação do modelo em um ambiente com um número maior de interações e validação junto a usuários reais. Além disso, a incorporação de outras métricas permitirá uma

avaliação mais ampla da qualidade e do desempenho do sistema de recomendação proposto.

6. CONCLUSÃO E RECOMENDAÇÃO PARA TRABALHOS FUTUROS

A implementação do Higia Way reflete um compromisso com a inovação tecnológica, proporcionando uma base sólida para o desenvolvimento do sistema de recomendação personalizada. Este trabalho apresentou um mecanismo de recomendação personalizada de conteúdos, fundamentado em um modelo voltado para a aprendizagem informal no contexto da Saúde Materna. O Higia Way foi desenvolvido para oferecer recomendações personalizadas de conteúdos de saúde a gestantes, colocando-as como protagonistas no acompanhamento de sua gestação e nos cuidados com sua saúde.

A solução implementada permite a recomendação de conteúdos relevantes para cada perfil de usuária, integrando dados coletados por meio da interação com ferramentas mobile e informações fornecidas diretamente pelas usuárias. Como principal contribuição, destaca-se o desenvolvimento de um sistema de recomendação capaz de fornecer conteúdos alinhados ao perfil e ao contexto de cada gestante, garantindo maior precisão e personalização nas sugestões.

Além disso, os resultados obtidos indicam uma melhoria significativa nas taxas de acerto das recomendações. Esse avanço foi possível graças à implementação de um mecanismo híbrido de recomendação, que combina diferentes técnicas, incluindo recomendações baseadas em similaridade, moderação e filtragem colaborativa, tornando-o capaz de fornecer recomendações mais eficazes e alinhadas às necessidades individuais das usuárias. Dessa forma, o Higia Way se estabelece como uma solução inovadora para auxiliar gestantes no acesso a informações relevantes para sua saúde e bem-estar.

6.1 Limitações Identificadas

Apesar dos resultados promissores, o estudo apresentou desafios:

1. Ambiente Simulado vs. Realidade:

- A validação com apenas 5 usuárias fictícias não captura toda a complexidade de um cenário real.
- Solução proposta: Testes em produção com pelo menos 50 gestantes.

2. Viés nos Dados de Conteúdo:

- A base de 100 itens priorizou temas comuns (ex.: nutrição), deixando nichos (ex.: diabetes gestacional) subrepresentados.
- Solução proposta: Parceria com hospitais para ampliação do acervo.

3. Dependência de Moderadores:

- A curadoria manual exige atualização frequente por especialistas.
- Solução proposta: Adoção de IA generativa para sumarizar artigos médicos.

6.2 Trabalhos Futuros

Embora este trabalho tenha alcançado contribuições significativas, algumas direções futuras podem ser exploradas para aprimorar ainda mais a pesquisa. Entre elas, destacam-se:

- Estudo de caso com gestantes no ambiente Higia Way: Realizar uma avaliação prática da ferramenta junto às usuárias, permitindo que gestantes interajam com o sistema para analisar sua utilidade, facilidade de uso e a experiência de preenchimento dos dados de saúde. Além disso, será possível verificar a relevância dos conteúdos recomendados e identificar possíveis melhorias.
- Aplicação de novas métricas de avaliação: Com a validação empírica realizada diretamente com as gestantes, será possível empregar métricas adicionais que forneçam resultados mais abrangentes e precisos. Isso permitirá uma análise mais aprofundada da eficácia do sistema, garantindo que os resultados obtidos nas simulações estejam alinhados com os objetivos propostos nesta dissertação.

6.2.1 Expansão da Validação Empírica

- Estudo Longitudinal com Gestantes Reais.
- Implementar o Higia Way em unidades de saúde e monitorar.
- Taxa de adesão ao sistema.
- Impacto no conhecimento sobre cuidados pré-natais (ex.: testes pré e pós-uso).
- Exemplo de métricas a coletar:
 - % de gestantes que realizaram todas as consultas recomendadas.
 - Nível de satisfação com as recomendações (escala Likert).

6.2.2 Aprimoramentos Técnicos

- Inclusão de Novas Fontes de Dados.
- Integrar wearables (ex.: monitores de pressão arterial) para recomendações em tempo real.
- Exemplo:
 - "Se uma gestante apresenta pressão elevada, o sistema sugere conteúdos sobre pré-eclâmpsia."
- Otimização do Algoritmo Híbrido:
 - Testar outras técnicas (ex.: Deep Learning para análise de sentimentos em feedbacks escritos).
 - Ponderação adaptativa (ex.: aumentar peso da moderação em casos de alto risco).

6.2.3 Sustentabilidade e Escalabilidade

- Modelo de Governança de Dados.
- Criar um comitê médico-tecnológico para revisão semestral dos conteúdos.
- Parcerias Estratégicas.
- Colaboração com SUS para disseminação em postos de saúde.

REFERÊNCIAS

- BARRETO, L. P. UXCHECKMOMS: UMA METODOLOGIA PARA AVALIAÇÃO DA EXPERIÊNCIA DO USUÁRIO E USABILIDADE DE APLICATIVOS MÓVEIS PARA O PERFIL DE MULHERES GESTANTES E PUÉRPERAS (2023). Disponível em: <<https://ppgcti.ufersa.edu.br/dissertacoes-turma-2021/>>. Acesso em: 10 Jul. 2024.
- BATISTA, S. C. M. Sistema de Recomendação Nutricional para Pacientes com Diabetes Mellitus Tipo 2 (2020). Disponível em: <chrome-extension://efaidnbmnnnibpcajpcglclefindmkaj/https://recipp.ipp.pt/bitstream/10400.22/17589/1/DM_SaraBatista_2020_MECIM.pdf>. Acesso em: 08 mar. 2024.
- BREESE, John S.; HECKERMAN, David; KADIE, Carl. Empirical Analysis of Predictive Algorithms for Collaborative Filtering. Morgan Kaufmann Publishers Inc., Madison, Wisconsin, p. 43–52, 1998. DOI: <https://dl.acm.org/doi/10.5555/2074094.2074100>.
- Brandão, L. C. P. (2020). Wavelet-Based Cancer Drug Recommender System. Polytechnic Institute of Coimbra.
- CARDOSO, Telmo André Moreira. Sistema de recomendação para uma loja online de livros. 2022. Dissertação de Mestrado. Universidade do Minho (Portugal).
- COSTA, Emerson Luís Nunes; LEVANDOWSKI, Daniela Centenaro; GRZYBOWSKI, Luciana Suárez. Perfil de puérperas e satisfação com assistência em saúde materno-infantil. Revista Psicologia e Saúde, p. 91-105, 2022.
- DE SOUZA BOEIRA, Juliana; LARENTIS, Fabiano; DA COSTA, Luana Folchini. Aprendizagem formal e informal no desenvolvimento de gestores: estudo de caso em IES. Revista Gestão Organizacional, v. 15, n. 3, p. 198-215, 2022.
- DOS SANTOS FIGUEIREDO, Letícia Marlene et al. Pré-natal psicológico como uma possibilidade de cuidado integral à saúde materna: uma revisão integrativa da literatura. Psicologia e Saúde em debate, v. 8, n. 1, p. 1-13, 2022.
- FIGUEIREDO, C. E. M. Sistema de recomendação no âmbito da prevenção de sintomas de ansiedade e depressão (2022). Disponível em: <chrome-extension://efaidnbmnnnibpcajpcglclefindmkaj/https://recipp.ipp.pt/bitstream/10400.22/21354/1/DM_CarlosFigueiredo_2022_MEIA.pdf>. Acesso em: 08 mar. 2024.
- GIMENEZ, Adriane Barbosa. Estratégias de aprendizagem no trabalho: Uma prática exigida pela atualidade. Gestão e Sociedade, v. 14, n. 37, p. 3306-3337, 2020.
- HUZAIRIN, Huzairin; PUTRAWAN, Gede Eka; RIADI, Bambang. Technology and language learning: English as a Foreign Language learners' use of smartphones for online informal learning in Indonesia. Texto Livre: Linguagem e Tecnologia, v. 13, n.

3, p. 103-120, 2020.

INTERNATIONAL BUSINESS MACHINES CORPORATION (IBM). O que é filtragem baseada em conteúdo? 2024. Disponível em: <https://www.ibm.com/br-pt/topics/content-based-filtering>. Acesso em: 20 fev. 2025.

INTERNATIONAL BUSINESS MACHINES CORPORATION (IBM). O que é um mecanismo de recomendação? 2024. Disponível em: <https://www.ibm.com/br-pt/think/topics/recommendation-engine>. Acesso em: 20 fev. 2025.

PIMENTA, D. A. A. Desenvolvimento de componentes de configuração e treino de algoritmos de Machine Learning no Sistema de Recomendação de Medicamentos Anticancerígenos (SiReMA). Disponível em: <chrome-extension://efaidnbmninnibpcajpcgclefindmkaj/https://comum.rcaap.pt/bitstream/10400.26/43441/1/Diogo_Pimenta.pdf>. Acesso em: 07 mar. 2024.

PERRONI, Mariana. Inteligência Artificial: Futuro da Saúde. Futuro da Saúde, 2024. Disponível em: https://futurodasaude.com.br/materiais/ebook-inteligencia-artificial/?utm_source=chatgpt.com. Acesso em: 20 fev. 2025.

SILVA, S. D.; NETO, A. F. S. et al. Um ambiente de aprendizagem informal com recomendações de conteúdos para portadores de doenças crônicas. In: IOP PUBLISHING. VIII Congresso Brasileiro de Informática na Educação (CBIE 2019). Disponível: <http://milanesa.ime.usp.br/rbie/index.php/sbie/article/download/8881/6434>.

SANTOS, Suzanne Loures; DURÃO, Frederico Araújo. Um sistema de recomendação de rotas turísticas baseado em filtragem colaborativa. Texto Livre, v. 16, p. e41397, 2023.

Fonte: Awari Bookstore. Disponível em: <https://thaispatricio.medium.com/awari-bookstore-recsys-cc50dba00cf1>. Acesso em: 05 mar. 2024.

LOPS, Pasquale; GEMMIS, Marco de; SEMERARO, Giovanni. Content-based Recommender Systems: State of the Art and Trends. In: RICCI, Francesco et al. (Ed.).

Laal, M. (2020). "Lifelong Learning and Technology." *Procedia - Social and Behavioral Sciences*, 28, 872-876.

Recommender Systems Handbook. Boston, MA: Springer US, 2011. P. 73–105. ISBN 978-0-387-85820-3. DOI: 10.1007/978-0-387-85820-3_3. Disponível em: <http://dx.doi.org/10.1007/978-0-387-85820-3_3>.

Matos, P. (2020). Hybrid Recommendation System for Young Athletes Training Advice.

MATOS, Pedro Chamberlain. Estudo comparativo de algoritmos de sistemas de recomendação de filmes. 2021.

MA, Xin; LI, Mingyue; LIU, Xuguang. Advancements in Recommender Systems: A Comprehensive Analysis Based on Data, Algorithms, and Evaluation. arXiv preprint arXiv:2407.18937, 2024. Disponível em: <https://arxiv.org/abs/2407.18937>. Acesso em: 20 fev. 2025.

MASCARENHAS, Victor Hugo Alves et al. COVID-19 e a produção de conhecimento sobre as recomendações na gravidez: revisão de escopo. Revista Latino-Americana de Enfermagem, v. 28, p. e3348, 2020.

Organização Pan-Americana da Saúde (OPAS). (2022, 30 de março). OMS Pede Atenção à Qualidade para Mulheres e Recém-Nascidos nas Primeiras Semanas. Recuperado de <https://www.paho.org/pt/noticias/30-3-2022-oms-pede-atencao-qualidade-para-mulheres-e-recem-nascidos-nas-primeiras-semanas>

ORGANIZAÇÃO MUNDIAL DA SAÚDE. Saúde materna: OMS, 2024. Disponível em: <https://www.who.int/health-topics/maternal-health#tab=tab_1>. Acesso em: 07 mar. 2024.

Preparação de dados: o que é e por que é importante?. ENGINEERING BRASIL, 2023. Disponível em: <<https://blog.engdb.com.br/preparacao-de-dados-o-que-e/>>. Acesso em: 11 de mar. de 2023.

RAZA, Shaina; RAHMAN, Mizanur; KAMAWAL, Safiullah; TOROGHI, Armin; RAVAL, Ananya; NAVAHA, Farshad; KAZEMEINI, Amirmohammad. A Comprehensive Review of Recommender Systems: Transitioning from Theory to Practice. arXiv preprint arXiv:2407.13699, 2024. Disponível em: <https://arxiv.org/abs/2407.13699>. Acesso em: 20 fev. 2025.

SCHRAMMEL, Lucca Alexandre et al. Ferramenta de recomendação híbrida de objetos de aprendizagem com predição das necessidades personalizadas de cada estudante. 2023.

VARGAS, André Prisco et al. Sistema de recomendação baseado no elo para problemas de pré-cálculo: Um experimento com calouros universitários. In: Anais do XXXI Simpósio Brasileiro de Informática na Educação. SBC, 2020. p. 1213-1222.

YUAN, Xiaofeng et al. Singular value decomposition based recommendation using imputed data. Knowledge-Based Systems, v. 163, p. 485–494, 2019. ISSN 0950-7051. DOI: <https://doi.org/10.1016/j.knosys.2018.09.011>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0950705118304623>>.

ZHANG, Sheng et al. Using singular value decomposition approximation for collaborative filtering. In: IEEE. SEVENTH IEEE International Conference on E-Commerce Technology (CEC'05). [S.l.: s.n.], 2005. P. 257–264. DOI: 10.1109/ICECT.2005.102.

ZHANG, Qian; LU, Jie; JIN, Yaochu. Artificial intelligence in recommender systems. *Complex & Intelligent Systems*, v. 7, n. 1, p. 439–457, 2021. Disponível em: <https://link.springer.com/article/10.1007/s40747-020-00212-w>. Acesso em: 17 mar. 2025.