

Proposta e Desenvolvimento de uma Estratégia de Aprendizagem Adaptativa Baseada em Recuperação de Informação para a Plataforma TôSabendo

Mateus do Carmo Eleto Hamade¹, Guilherme Tavares de Assis²

Departamento de Computação – Universidade Federal de Ouro Preto
Ouro Preto, Minas Gerais

mateus.hamade@aluno.ufop.edu.br, gtassis@ufop.edu.br

Abstract. *This article presents the proposal, development, and validation of an adaptive learning strategy for the TôSabendo platform, aimed at solving questions through Quizzes. The strategy uses Information Retrieval (IR) models and a user model, which are responsible for adapting the content according to the individual needs and learning pace of students. Through practical experiments using three IR models: Vector Model, Extended Boolean Model, and Probabilistic Model, positive results were obtained regarding question retrieval. Furthermore, through the Lighthouse tool, satisfactory usability of the platform integrated with the adaptive learning strategy was verified.*

Resumo. *Este artigo apresenta a proposta, o desenvolvimento e a validação de uma estratégia de aprendizagem adaptativa para a plataforma TôSabendo, voltada à resolução de questões por meio de Quizzes. A estratégia utiliza modelos de Recuperação de Informação (RI) e um modelo de usuário, responsáveis por adaptar o conteúdo de acordo com as necessidades individuais e ritmos de aprendizagem dos estudantes. Por meio de experimentos práticos utilizando três modelos de RI (Modelo Vetorial, Modelo Booleano Estendido e Modelo Probabilístico) foram obtidos resultados positivos quanto à recuperação das questões. Além disso, por meio da ferramenta Lighthouse, verificou-se uma usabilidade satisfatória da plataforma integrada à estratégia de aprendizagem adaptativa.*

1. Introdução

No campo educacional, os desafios enfrentados pelos docentes em todos os níveis estão frequentemente relacionados à dificuldade de engajar os estudantes no processo de ensino-aprendizagem [França et al. 2021]. Esses obstáculos estão ligados ao uso de metodologias e paradigmas tradicionais de ensino que, muitas vezes, são ineficazes para atender às necessidades da chamada geração dos “Nativos digitais” que, segundo Prensky (2001), refere-se à geração de indivíduos que cresceram imersos na era tecnológica. Embora as tecnologias digitais tenham permeado diversas esferas da sociedade, é notável que seu impacto na educação, por vezes, não se manifesta de maneira tão evidente. O relatório Horizon [Johnson et al. 2016] evidencia a falta de incorporação da tecnologia digital nas salas de aula, especialmente no que diz respeito a tecnologias emergentes, tais como *Bring Your Own Device* (BYOD), análise de aprendizagem e aprendizagem adaptativa, realidade aumentada e virtual, e robótica.

Segundo, no contexto de Instituições de Ensino Superior (IESs), as ferramentas predominantemente utilizadas pelos professores consistem de apresentações visuais e plataformas virtuais, que atuam como suporte às aulas ministradas. Essa constatação ressalta a necessidade de uma abordagem mais integrada e inovadora na aplicação das tecnologias digitais no contexto educacional, visando potencializar a experiência de aprendizagem. Neste cenário, observa-se uma desconexão significativa entre os estudantes, que nasceram e cresceram imersos em um ambiente tecnológico, e as metodologias de ensino tradicionais adotadas pelas IESs: essa discrepância entre o universo digital dos alunos e as práticas pedagógicas convencionais pode contribuir significativamente para o desinteresse dos mesmos, refletindo-se em seus desempenhos acadêmicos. Tal cenário levou ao crescimento de uma área denominada Gamificação que, segundo Burke (2015), envolve o uso de *design* de experiências digitais e mecânicas de jogos para motivar e engajar as pessoas para que elas atinjam seus objetivos.

De acordo com França et al. (2021), a plataforma TôSabendo, contexto deste trabalho, é uma ferramenta gamificada de *quizzes* educacionais projetada para IESs. Os *quizzes* consistem em jogos de perguntas e respostas que abordam conteúdos apresentados em sala de aula. Ao integrar elementos de gamificação, a plataforma transforma o aprendizado em uma experiência interativa e envolvente, visando engajar os discentes no processo de ensino-aprendizagem tornando-o mais eficiente e atrativo para os estudantes.

Entretanto, apesar de existirem ferramentas que incorporam a gamificação no processo educacional, como a plataforma TôSabendo, ainda persiste um desafio significativo: a transmissão de conhecimento de forma homogênea. Isso significa que, embora as estratégias de gamificação visem tornar o processo de aprendizado mais atraente aos “nativos digitais”, é importante considerar as necessidades específicas de cada aluno, assim como suas preferências e estilo de aprendizagem. Sendo assim, este trabalho propõe desenvolver e validar uma estratégia de aprendizagem adaptativa para a plataforma TôSabendo, cuja finalidade é personalizar o percurso educacional dos alunos, por meio de um modelo de usuário, responsável por adaptar o conteúdo de acordo com suas necessidades individuais. Para isso, foram desenvolvidos e analisados modelos de RI, baseados em questões previamente elaboradas e presentes na plataforma, que permitem a localização de questões específicas e similares.

Este artigo encontra-se estruturado como segue. A Seção 2 descreve brevemente a plataforma TôSabendo, contexto deste trabalho. A Seção 3 discute alguns trabalhos relacionados ao objetivo deste trabalho. A Seção 4 descreve o processo de desenvolvimento da estratégia proposta de aprendizagem adaptativa, incluindo sua arquitetura de funcionamento. A Seção 5 descreve os experimentos realizados e apresenta uma discussão sobre os resultados experimentais obtidos. Finalmente, a Seção 6 apresenta as conclusões do trabalho e as perspectivas de trabalho futuro.

2. Plataforma TôSabendo

A plataforma “Tô Sabendo” foi desenvolvida com o intuito de adotar os princípios da gamificação no campo educacional. Seu objetivo é auxiliar os estudantes de IESs no processo de ensino-aprendizagem, por meio da interação com jogos de perguntas e respostas, conhecidos como *Quizzes* [França et al. 2021]. A iniciativa busca transformar a forma pela qual os conteúdos educacionais são assimilados, tornando o aprendizado mais atra-

ente e eficaz. De modo geral, a plataforma apresenta os conteúdos na forma de um jogo de tabuleiro que simboliza um caminho de aprendizado que precisa ser percorrido. Cada posição do tabuleiro corresponde a uma pergunta, variando em nível de dificuldade, que incentiva o jogador a evoluir os conceitos dos conteúdos abordados pelo *Quiz*.

A plataforma, após ser desenvolvida, foi submetida a um estudo de caso experimental composto por duas etapas: avaliação por meio do Método de *Reeves*¹ e avaliação prática visando a preparação para o Exame Nacional de Desempenho de Estudantes (ENADE) por discentes do curso de Ciência da Computação de uma IES. Os resultados obtidos pelo método de *Reeves* foram considerados predominantemente positivos, concluindo-se que a plataforma *TôSabendo* propicia uma ferramenta de aprendizagem eficiente. Já a avaliação prática levou à obtenção do indicador de qualidade 5, o maior valor possível, na realização do ENADE pelos discentes do curso em questão: um resultado muito significativo. Posteriormente, algumas melhorias foram desenvolvidas e aplicadas na plataforma por [FERREIRA 2022] e [Oliveira 2024].

3. Trabalhos Relacionados

Esta seção apresenta trabalhos relevantes e semelhantes ao objetivo deste trabalho. Foram analisados diversos sistemas que exploram aspectos semelhantes, destacando-se:

- *Sistex* - Detectando a experiência do aluno [Possobom 2014]: sistema incorporado ao Moodle, que busca aplicar caminhos adaptados de acordo com o nível de experiência do aluno, identificado a partir de um questionário inicial.
- *Aedes em Foco* - Adaptando o conhecimento com foco no *Aedes aegypti* [Mendes 2023]: Ambiente Virtual de Aprendizagem (AVA) com recursos adaptativos, voltado para o ensino sobre arboviroses transmitidas pelo *Aedes aegypti*.
- *Duolingo* - Adaptando o ensino de idiomas [Freeman 2023]: sistema que busca tornar o aprendizado de idiomas mais divertido e dinâmico, sendo capaz de adaptar as atividades de acordo com o desempenho do usuário.

A Tabela 1 apresenta uma comparação entre este trabalho e os demais descritos nesta subseção, com base em alguns aspectos relevantes:

Tabela 1. Comparação entre as plataformas *Aedes em Foco*, *Sistex*, *Duolingo* e *Tô Sabendo*.

Aspecto	<i>Aedes em Foco</i>	<i>Sistex</i>	<i>Duolingo</i>	<i>Tô Sabendo</i>
Aprendizagem Adaptativa	x	x	x	x
Hipermídia Adaptativa		x	x	
Modelo de Usuário		x	x	x
Modelos de RI			x	x
Plataforma Própria			x	x
Foco de IESs				x
Conteúdo diverso		x		x

¹Segundo Pinto Andres and Cybis (2000), o método de *Reeves* avalia *software* educacional utilizando critérios pedagógicos e de usabilidade por meio de uma escala não dimensionada.

De acordo com a Tabela 1, este trabalho distingue-se por sua abordagem e área de aplicação da estratégia de aprendizagem adaptativa. Em contraste com os trabalhos mencionados, dois deles empregam estratégias de Hipermídia Adaptativa (HA) em sistemas mais rígidos o que impossibilitam a aplicação de modelos automáticos de adaptação do conteúdo; por sua vez, o terceiro trabalho adota uma abordagem muito eficaz utilizando aprendizado de máquina, mas possui o objetivo central de ensinar idiomas.

4. Desenvolvimento

Esta seção apresenta a estratégia de aprendizagem adaptativa proposta para a plataforma TôSabendo.

4.1. Arquitetura de funcionamento da estratégia proposta

A Figura 1 apresenta a arquitetura de funcionamento da estratégia proposta de aprendizagem adaptativa a partir da perspectiva de um usuário jogador da plataforma TôSabendo, consistindo nos passos:

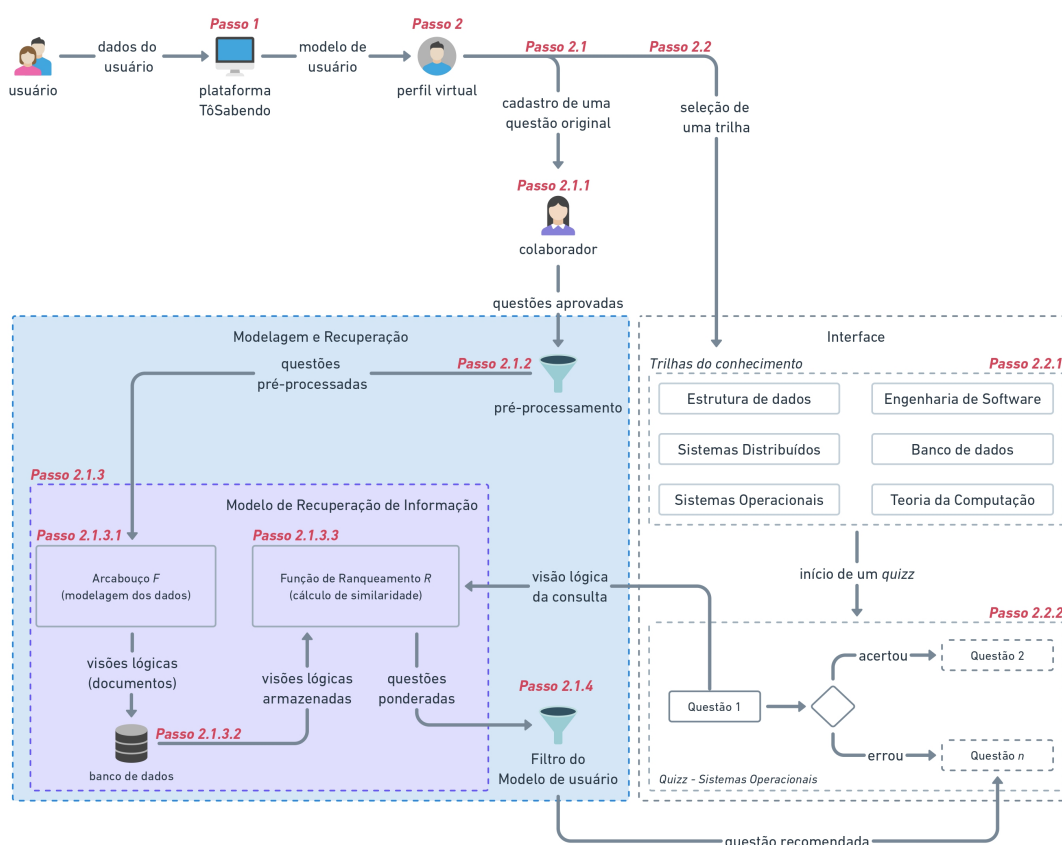


Figura 1. Arquitetura da estratégia de aprendizagem adaptativa

- Passo 1: Por meio do cadastro na plataforma, um usuário envia uma coleção de dados que são utilizados para personalizar a experiência do mesmo. Assim, tais dados são armazenados e um modelo de usuário personalizado é criado; esse modelo é responsável por organizar e gerenciar as informações do usuário enquanto ele interage com a plataforma por meio do perfil virtual.

- Passo 2: Após o cadastro inicial, o usuário tem a opção de participar na plataforma de duas maneiras: ele pode optar por contribuir para a expansão do banco de dados da plataforma, cadastrando novas questões, ou pode escolher jogar os *Quizzes* disponíveis no ambiente, criados por outros usuários. Cada opção envolve caminhos diferentes, detalhados nos passos 2.1 e 2.2.
- Passo 2.1: O cadastro de questões é fundamental para a aprendizagem adaptativa pois, para recomendar questões com um maior grau de precisão, é necessário um banco de dados robusto e diversificado. O processo de cadastro e recuperação das questões é composto pelos passos 2.1.1 a 2.1.4.
- Passo 2.1.1: Ao cadastrar uma questão na plataforma, o conteúdo enviado pelo usuário passa por um processo de avaliação. Um colaborador responsável avalia a questão, podendo aceitá-la ou descartá-la.
- Passo 2.1.2: As questões originais aprovadas pelo colaborador são submetidas a técnicas de Processamento de Linguagem Natural (PLN) para remover características irrelevantes e preparar os dados para serem introduzidos no modelo de RI; isso inclui a aplicação de métodos para gerar as visões lógicas das questões.
- Passo 2.1.3: O modelo de RI é responsável por receber as questões no formato ideal e transformá-las conforme suas características específicas, podendo envolver a representação em forma de vetores, conjuntos e outras estruturas. Após a modelagem, o modelo realiza a busca por questões similares à questão comparada, retornando uma lista de questões relevantes para a consulta. Este processo envolve os passos 2.1.3.1 a 2.1.3.3.
- Passo 2.1.3.1: O arcabouço F recebe as questões no formato ideal e realiza ajustes de acordo com as características específicas de implementação de cada modelo. Após esse processamento, as visões lógicas, com seus dados processados, são armazenadas.
- Passo 2.1.3.2: As visões lógicas das questões armazenadas no banco de dados ficam prontas para serem utilizadas na função de ranqueamento. Quando um usuário inicia um *Quiz*, o sistema pode recuperar essas questões e recomendá-las com base em critérios de relevância.
- Passo 2.1.3.3: A função de ranqueamento compara as questões armazenadas no banco de dados com a questão de consulta. Ela retorna uma lista de questões similares, ordenadas de forma decrescente pela similaridade em relação à consulta;
- Passo 2.1.4: A partir do conjunto de questões similares, o modelo de usuário seleciona apenas aquelas que são mais relevantes para as necessidades do usuário. Esse modelo avalia as questões com base no histórico de interações do usuário com a plataforma, garantindo que a questão mais adequada seja recomendada como a próxima a ser respondida.
- Passo 2.2: A seleção de um *Quiz* permite que o usuário escolha e jogue o *Quiz* desejado, considerando suas preferências e necessidades. O processo de seleção e realização do *Quiz* é composto pelos passos 2.2.1 e 2.2.2.
- Passo 2.2.1: Uma trilha de estudo consiste em um *Quiz* que o usuário pode selecionar para desenvolver questões. Esses *Quizzes* são desenvolvidos por Colaboradores e podem envolver qualquer tipo de conteúdo em formato de questões de múltipla escolha.
- Passo 2.2.2: Ao definir o *Quiz* que deseja jogar, o usuário é direcionado para uma interface onde as questões são apresentadas uma de cada vez. As questões

seguintes são apresentadas de acordo com o desempenho do estudante: se ele acertar a questão, a próxima será apresentada conforme a sequência definida para aquele *Quiz*. Caso contrário, a próxima questão será dinâmica ajustando-se às necessidades do usuário e à sua interação com a plataforma.

Como destacado na Figura 1, o pré-processamento inicial, o modelo de RI e o filtro de usuário desempenham um papel crucial no processo de adaptação das questões. Na sequência, as Subseções 4.1.1 e 4.1.2, expandem, respectivamente, o pré-processamento das questões e o modelo de RI de maneira detalhada.

4.1.1. Pré-processamento

Segundo Baeza-Yates e Ribeiro-Neto (2013), o pré-processamento é responsável por fornecer uma visão lógica dos documentos, ou seja, uma representação dos termos que os compõem. Assim, o pré-processamento é realizado para gerar um vocabulário que represente da melhor forma o conteúdo dos documentos. A Figura 2 apresenta os passos do processo, a saber:

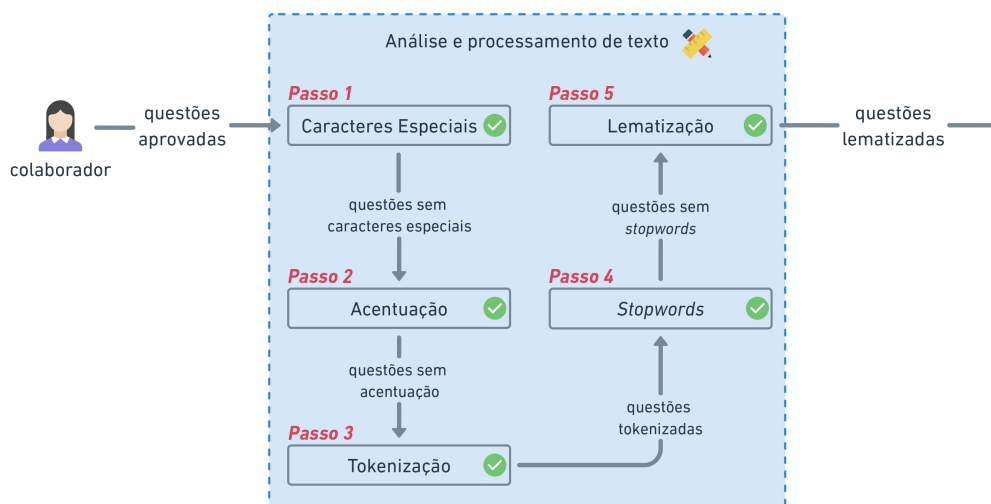


Figura 2. Etapas do pré-processamento das questões originais.

- Passo 1: envolve a remoção de caracteres especiais, como pontuações, símbolos e outros elementos não alfabéticos que possam interferir na análise posterior dos dados.
- Passo 2: envolve a remoção de acentos, padronizando as palavras, facilitando a comparação e evitando inconsistências causadas por variações ortográficas.
- Passo 3: envolve a divisão do texto em unidades menores ou “tokens”, que correspondem a palavras ou termos individuais. Essa divisão é essencial, uma vez que o modelo de RI processa e analisa os dados neste formato.
- Passo 4: envolve a remoção de *stopwords*, ou seja, termos que não têm importância semântica no texto, evitando ruído no processo de análise.
- Passo 5: envolve a lematização dos termos, ou seja, transforma os termos em sua forma raiz, reduzindo significativamente o tamanho do vocabulário e otimizando o processamento.

4.1.2. Modelo de RI

Após o pré-processamento das questões, a próxima etapa consiste na inserção das visões lógicas no modelo de RI. As etapas de modelagem das visões lógicas pelo arcabouço F até o cálculo da similaridade estão ilustradas na Figura 3, possuindo os passos:

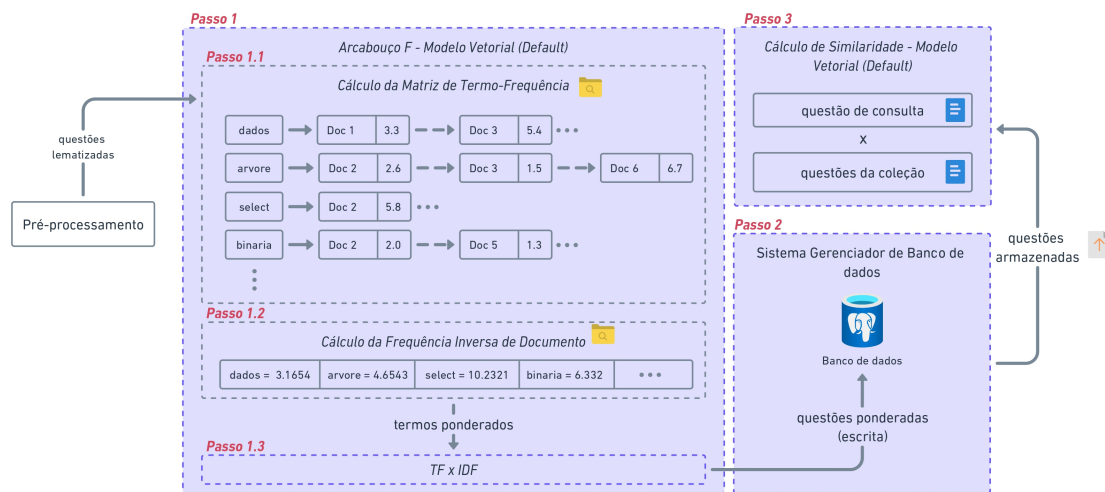


Figura 3. Etapas da ponderação das questões pré-processadas.

- Passo 1: Consiste no arcabouço do modelo de RI escolhido pelo o usuário, que será responsável por receber as visões lógicas das questões previamente processadas, retornando a ponderação das questões e dos termos que as compõem. Engloba os passos seguintes 1.1 a 1.3.
- Passo 1.1: Gera uma matriz de termo-documento para organizar os termos e seus respectivos documentos em que aparecem e calcula a matriz de Termo Frequência (TF), que mede a importância de um termo dentro de um documento específico; assim, cada termo estará vinculado a um documento com sua respectiva frequência, baseada na ponderação de Normalização Logarítmica.
- Passo 1.2: Calcula a Frequência Inversa de Documento (IDF), baseada na ponderação de Frequência Inversa. O IDF avalia a importância de um termo em relação à coleção de documentos como um todo.
- Passo 1.3: Multiplica os valores TF e IDF calculados, resultando na ponderação final dos termos em cada questão.
- Passo 2: Consiste no armazenamento das questões, junto com seus respectivos termos ponderados, em um banco de dados. Dessa forma, as questões ficam prontas para serem recuperadas e comparadas com a questão de consulta.
- Passo 3: Recupera as questões armazenadas e calcula a similaridade com a consulta, utilizando o cálculo do cosseno (Modelo Vetorial). O cálculo do cosseno é utilizado para determinar o ângulo entre os vetores que representam essas questões. Assim, um valor mais alto indica que os vetores estão próximos, podendo ser uma questão relevante, enquanto um valor mais baixo indica que eles estão distantes.

Dessa forma, é gerada uma lista de questões, ordenadas em forma decrescente, apresentando as mais similares no topo. Esse resultado serve como entrada para o filtro

do modelo de usuário, responsável por receber essas questões e selecionar aquelas que são relevantes de acordo com as características do usuário em questão.

4.2. Aplicação da estratégia proposta na plataforma TôSabendo

A estratégia de aprendizagem adaptativa proposta neste trabalho é aplicada ao se usar a plataforma TôSabendo. Após acessar a plataforma e selecionar um dos *quizzes* disponíveis na tela principal, o usuário é direcionado para a resolução do próprio *quiz* selecionado (vide Figura 4), onde as questões são apresentadas uma por vez.



Figura 4. Interface de resolução de um *quiz*.

A estratégia de aprendizagem adaptativa funciona, inicialmente, da seguinte maneira: se o criador do *quiz* habilitou tal funcionalidade, as questões seguintes do *quiz* são determinadas pelo desempenho do usuário na questão anterior. Caso o usuário responda incorretamente ou indique que seu nível de confiança ao marcar aquela alternativa foi baixo, a próxima questão será semelhante à anterior, permitindo que o usuário revise e fixe o conteúdo. Quando uma questão é recomendada (vide questão da Figura 5 recomendada de acordo com a questão da Figura 4), o sistema exibe uma mensagem indicando que aquela questão foi sugerida pelo modelo de RI como sendo a melhor questão a ser resolvida na sequência.



Figura 5. Questão recomendada.

5. Análise Experimental

Nesta seção, são apresentados os experimentos realizados (vide Subseção 5.1) e os resultados obtidos (vide Subseção 5.2), organizados em dois focos principais: o primeiro, direcionado à eficácia dos modelos de RI, e o segundo, direcionado a critérios de qualidade da plataforma TôSabendo por meio da ferramenta *Lighthouse*.

5.1. Descrição da experimentação prática

Para realizar os experimentos do primeiro foco, relacionados aos modelos de RI implementados, foram definidas as questões que serviriam como entrada para os modelos; logo, foi desenvolvido um banco de dados composto por 4.296 questões. Em seguida, foi escolhida uma questão padrão a ser utilizada como consulta. A partir dessa questão, 36 questões foram selecionadas, como similares e nomeadas como “gabaritos”, com base na semelhança dos termos presentes, garantindo a representação adequada da resposta esperada. Essa seleção foi feita de maneira arbitrária, por inspeção visual e textual da similaridade com a questão de consulta. Ao final da execução de cada modelo, espera-se que esses “gabaritos” apareçam entre os primeiros elementos da lista de similaridade.

Foi necessária também a definição das configurações de cada um dos modelos implementados. A Tabela 2 apresenta os modelos e seus parâmetros.

Tabela 2. Configuração dos modelos de Recuperação de Informação

Modelo	Configuração
Vetorial	Normalização Logarítmica (TF), Frequência Inversa (IDF)
Probabilístico	1 iteração
Booleano Estendido	$p = m$

Vale ressaltar que a seleção dos modelos adotados foi feita de forma exploratória, buscando diferentes abordagens. Além disso, as configurações apresentadas (vide Tabela 2) foi definida com base nos resultados mais adequados a partir dos ajustes dos parâmetros.

Por fim, foi necessária a configuração do ambiente e das questões para garantir que os modelos fossem testados em diferentes perspectivas, ajudando a avaliar se a presença ou a ausência de informações adicionais influenciam a eficácia dos modelos na recuperação das questões similares. Para isso, foram definidas quatro configurações, relativas a diferentes ajustes na estrutura das questões, a saber:

- Configuração Completo-Completo (CC): para a questão de consulta e as questões do banco de dados, é considerado todo o texto (título, enunciado e alternativas);
- Configuração Completo-Enunciado (CE): para a questão de consulta, é considerado todo o texto (título, enunciado e alternativas); para as questões do banco, é considerado apenas o enunciado;
- Configuração Enunciado-Completo (EC): para a questão de consulta, é considerado apenas o enunciado; para as questões do banco, é considerado todo o texto (título, enunciado e alternativas);
- Configuração Enunciado-Enunciado (EE): para a questão de consulta e as questões do banco de dados, é considerado apenas o enunciado.

Já o segundo foco experimental, visando a análise da plataforma TôSabendo integrada aos modelos de RI, envolveu a configuração e execução da ferramenta *Lighthouse* com o intuito de testar quantitativa e qualitativamente a plataforma, identificando aspectos que impactam a experiência do usuário e verificando métricas de desempenho, acessibilidade, SEO e outros critérios de qualidade para *softwares web*. Todos os testes foram feitos em dispositivos (*Mobile* e *Desktop*). Especificamente para a página de “Resolução do Quizz”, foi realizado um teste prático utilizando um *quizz* com 15 questões, enquanto a ferramenta *Lighthouse* monitorava o desempenho durante todo o processo de resolução. Esse procedimento permitiu capturar métricas de “Desempenho” e “Práticas Recomendadas” ao longo da interação do usuário, proporcionando uma análise mais precisa do comportamento da plataforma.

5.2. Análise dos resultados obtidos

No primeiro foco, para cada modelo de RI, foi definido um limiar de relevância para as questões recuperadas: 10% para o Modelo Vetorial, e 20% para os modelos Probabilístico e Booleano Estendido, definidos de forma arbitrária, levando em consideração a esparsidade das questões gabaritos retornadas pelos modelos. Esse limiar inclui as questões similares “gabarito”, bem como questões que são minimamente similares à consulta, mas não estão entre as mais similares. A partir desses critérios, foram geradas matrizes de confusão² para cada um dos modelos, permitindo calcular os indicadores de desempenho, incluindo precisão, revocação e a medida F1. A Figura 6 apresenta o desempenho dos três modelos em relação à métrica F1.




Figura 6. Comparação entre os modelos de RI.

A partir das informações apresentadas, observa-se que o modelo Modelo Vetorial apresenta melhores resultados na maioria das configurações analisadas, mantendo um

²Segundo Souza e Gonçalves (2020), a matriz de confusão, também chamada de matriz de erro, é uma tabela que permite avaliar o desempenho de um algoritmo. Ela identifica o erro global de classificação de cada categoria e como ocorreram as confusões entre as categorias.

equilíbrio com o Modelo Probabilístico na configuração EC. O Modelo Probabilístico, por sua vez, demonstra taxas consistentes e equilibradas em todos os níveis, apresentando uma queda apenas na configuração EE. Em contraste, o modelo Modelo Booleano Estendido destaca-se como o menos eficaz entre os modelos testados, exibindo grandes variações de desempenho em todas as configurações, o que o classifica como o modelo com os piores resultados.

Portanto, de forma geral, observa-se que o Modelo Vetorial apresentou melhores resultados em comparação aos modelos Probabilístico e Booleano Estendido, especialmente na configuração CC, que considera todos os elementos da questão de consulta e do banco de questões. Assim, o Modelo Vetorial foi escolhido como o mais adequado para ser utilizado na estratégia proposta de aprendizagem adaptativa para a plataforma TôSabendo. Apesar dos modelos Probabilístico e Booleano Estendido terem apresentado resultados inferiores, eles também foram incluídos na plataforma como opções adicionais para o usuário, uma vez que as questões anotadas como “gabaritos” apareceram como as mais semelhantes, embora com menos frequência que o Modelo Vetorial.

Essa escolha justifica-se pelo fato de que, no contexto da plataforma TôSabendo, as questões mais importantes não são todas aquelas retornadas pelo modelo. O usuário precisa apenas de uma questão similar àquela que acabou de resolver. Isso significa que a questão mais similar à questão de consulta deverá estar entre as primeiras da lista. O ideal é que os modelos consigam retornar de forma contínua essas questões “gabaritos”, para que, caso a primeira mais similar não possa ser recomendada pelo fato do usuário já tê-la resolvido, seja possível recomendar a próxima. Assim, espera-se que a próxima também seja uma questão similar.

O segundo foco consistiu na execução da ferramenta *Lighthouse* em todas as páginas do sistema, totalizando 26 execuções. Para cada página, foram gerados relatórios com as métricas avaliadas. A Figura 7 apresenta o resultado final dessas execuções, tanto para dispositivos *Mobile* quanto para *Desktop*, abrangendo todas as páginas do sistema.

Páginas	Desempenho		Acessibilidade		Práticas Recomendadas		SEO	
MODO "NAVEGAÇÃO"	Desktop	Mobile	Desktop	Mobile	Desktop	Mobile	Desktop	Mobile
Principal	98	76	90	90	100	100	83	83
Dados Pessoais	98	69	96	96	96	96	75	75
Metadados	98	69	96	96	96	96	75	75
Instituição	98	63	96	96	96	96	75	75
Login	98	96	96	96	100	100	83	83
Explorar	98	69	87	87	96	96	67	75
Ranking	98	75	87	88	96	96	67	67
Questões	98	63	88	88	96	96	67	67
Cadastrar Questões	98	70	87	87	96	96	67	67
Quizz	98	69	88	88	96	96	67	67
Cadastrar Quizzes	98	71	87	87	96	96	67	67
Modelos	98	60	87	87	96	96	67	67
Média total	98	70,83	90,41	90,50	96,66	96,66	71,66	71,66
Páginas	Desempenho		Acessibilidade		Práticas Recomendadas		SEO	
MODO "PERÍODO"	Desktop	Mobile	Desktop	Mobile	Desktop	Mobile	Desktop	Mobile
Resolução do Quizz	80	72,72	-	-	100	100	-	-

Figura 7. Resultado da avaliação da plataforma TôSabendo no *Lighthouse* (Desktop e Mobile)

A partir dos resultados obtidos (vide Figura 7), observa-se que, de uma forma

geral, os testes realizados apresentaram uma variação mínima, em relação a todas as métricas, de uma página para outra, indicando que o sistema tem um desempenho relativamente consistente, independente da página analisada. No entanto, é importante destacar que, embora as variações entre páginas sejam pequenas, há uma grande diferença entre os dispositivos (*Desktop* e *Mobile*), para a métrica de “Desempenho”, indicando que a plataforma está mais otimizada para dispositivos *Desktop*. Além disso, observa-se que, para todas as métricas calculadas, os resultados atingem valores próximos de 100%, sendo um indicativo de uma performance geral satisfatória. As métricas de acessibilidade também apresentam resultados positivos, refletindo que o sistema é relativamente acessível para todos os usuários, incluindo aqueles com deficiências. As práticas recomendadas seguem a mesma tendência, com valores igualmente elevados, o que demonstra a conformidade do sistema com as melhores práticas de desenvolvimento de *softwares web*.

O relatório gerado pela ferramenta *Lighthouse* apresenta tanto métricas quantitativas quanto recomendações qualitativas para otimização. Com base nos resultados obtidos, algumas possíveis melhorias foram identificadas como, por exemplo, carregamento lento da imagem principal da página e o uso excessivo de JavaScript e CSS. Logo, pode-se concluir que, apesar dos bons resultados obtidos a partir das métricas calculadas pelo *Lighthouse*, ainda existem melhorias simples que podem ser feitas para otimizar a plataforma, sem a necessidade de grandes alterações.

6. Conclusão

Buscando avaliar a estratégia implementada na plataforma TôSabendo, foram realizados experimentos com os modelos de RI a partir de quatro configurações na estrutura das questões. De forma geral, os resultados indicaram que os modelos vetorial e probabilístico apresentaram resultados superiores em comparação ao modelo booleano estendido, destacando-se o modelo vetorial como o melhor avaliado; por apresentar os melhores resultados, o modelo vetorial é o mais adequado para integração à plataforma TôSabendo. Além disso, apesar do desempenho inferior, os outros modelos avaliados foram integrados à plataforma, sendo essa integração viável, uma vez que todos conseguem recuperar questões relevantes, de forma eficaz, entre as primeiras retornadas.

Ademais, por meio dos resultados obtidos pela ferramenta *Lighthouse*, pode-se concluir que a plataforma TôSabendo, integrada à estratégia de aprendizagem adaptativa, atende satisfatoriamente critérios de qualidade envolvendo as métricas de desempenho, acessibilidade e práticas recomendadas, apresentando valores acima de 90 pontos. Quanto à métrica SEO, apesar de apresentar valores medianos (entre 50 e 89), para este trabalho em específico, essa métrica não tem um peso significativo, pois está relacionada à otimização para mecanismos de busca, ou seja, ao aumento da visibilidade do site.

Como perspectivas de trabalho futuro, pretende-se: (1) realizar estudos sobre novos modelos de RI, considerando novas abordagens e uma base de dados mais robusta; (2) desenvolver um modelo de usuário mais avançado, capaz de captar mais informações do usuário, como seu histórico escolar e acadêmico; (3) avaliar novas abordagens para aplicar a aprendizagem adaptativa dentro da plataforma TôSabendo; e (4) realizar experimentações práticas com usuários reais no intuito de comprovar a eficácia, já validada por meio dos experimentos feitos, da estratégia proposta e desenvolvida para aprendizagem adaptativa na plataforma TôSabendo.

Referências

- Baeza-Yates, R. and Ribeiro-Neto, B. (2013). *Recuperação de informação - 2ª ed: Conceitos e tecnologia das máquinas de busca*. Bookman.
- Burke, B. (2015). *Gamificar: Como a gamificação motiva as pessoas a fazerem coisas extraordinárias*. DVS Editora.
- FERREIRA, C. O. (2022). Desenvolvimento de uma estratégia de machine learning para aprimoramento da plataforma tósabendo. In: *UFOP, Ouro Preto, MG*.
- França, T. F., Ferreira, C. O., De Oliveira, D. L., De Assis, G. T., Ferreira, A. A., and Da Silva, E. J. (2021). Tósabendo: A platform to create engaging teaching and learning experiences. In *2021 XVI Latin American Conference on Learning Technologies (LACLO)*, pages 275–281. IEEE.
- Freeman, C. (2023). O método duolingo: os 5 princípios-chave que fazem o aprendizado ser eficaz e divertido. Acesso em: 3 fev. 2025.
- Johnson, L., Becker, S. A., Cummins, M., Estrada, V., Freeman, A., and Hall, C. (2016). *NMC horizon report: 2016 higher education edition*. The New Media Consortium.
- Mendes, S. R. P. N. (2023). Aedes em foco: ambiente virtual com recursos de aprendizagem adaptativa. Dissertação de mestrado profissional em ensino de ciências, Universidade Federal de Ouro Preto, Ouro Preto.
- Mercader, C. and Sallán, J. (2020). University teachers' perception of barriers to the use of digital technologies: the importance of the academic discipline. *International Journal of Educational Technology in Higher Education*, 17:4.
- Oliveira, G. C. F. (2024). Proposta, desenvolvimento e validação de uma estratégia para predição de desempenho de discentes na plataforma tósabendo. Dissertação de Graduação. Acesso em: 21 ago. 2025.
- Pinto Andres, D. and Cybis, W. d. A. (2000). Um estudo teórico sobre as técnicas de avaliação de software educacional. In *VI Congreso Argentino de Ciencias de la Computación*.
- Possobom, C. C. (2014). Sistex: Um sistema dinâmico para detectar a experiência do aluno. Dissertação de mestrado, Universidade Federal de Santa Maria. Acesso em: 21 ago. 2025.
- Prensky, M. (2001). Digital natives, digital immigrants part 2: Do they really think differently? *On the Horizon: The International Journal of Learning Futures*, 9(6):1–6.
- Souza, L. and Goncalves, A. (2020). A utilização de classificadores de texto na mineração de ideias agregando critérios de especialistas. *International Journal of Knowledge Engineering and Management*, 9.