

Ensino

Aplicação de técnicas de recomendação de recursos educacionais em um campus universitário

Application of educational resource recommendation techniques on a university campus

Martin Hideki Mensch Maruyama¹ , Luan Willig Silveira¹ , Vinícius Maran¹ 

¹Universidade Federal de Santa Maria, Santa Maria, RS, Brasil

RESUMO

O desenvolvimento da Internet ao longo dos anos trouxe consigo um aumento massivo da quantidade de dados presente na rede, fazendo com que a busca por itens específicos se tornasse uma tarefa lenta e complexa. Dessa forma, surgem ferramentas que têm o objetivo de filtrar informações dentro de websites e plataformas deixando de lado tudo o que for irrelevante e levando ao usuário somente aquilo que provavelmente irá lhe interessar. Essas ferramentas são chamadas de sistemas de recomendação. Além disso, a área da educação também se tornou afetada pelo problema de sobrecarga de dados, principalmente nos últimos anos com a popularização da educação online onde alunos passam a demandar por novos métodos de pesquisa e aprendizado além da sala de aula. Dessa forma, neste artigo, tem-se o objetivo de desenvolver um sistema de recomendação personalizado de recursos educacionais que, baseado nos interesses dos usuários, faça previsões e gere listas de itens que vão ao encontro de seus interesses. Assim espera-se também que essa plataforma possa ajudar na integração e desenvolvimento de campus universitários inteligentes.

Palavras-chave: Sistema de Recomendação; Campus Inteligente; Filtragem Colaborativa; Filtragem baseada em Conteúdo; Sistema Híbrido

ABSTRACT

The development of the Internet over the years has brought with it a massive increase in the amount of data present on the network, making the search for specific items a slow and complex task. Thus, tools have emerged with the goal of filtering information within websites and platforms, leaving aside everything that is irrelevant and providing the user with only what is likely to interest them. These tools are called recommendation systems. In addition, the field of education has also been affected by the problem of data overload, especially in recent years with the popularization of online education, where students demand new methods of research and learning beyond the classroom. Therefore, the

objective of this article is to develop a personalized recommendation system for educational resources that, based on users' interests, makes predictions and generates lists of items that match their interests. It is also hoped that this platform can help in the integration and development of intelligent university campuses.

Keywords: Recommendation Systems; Smart Campus; Collaborative Filtering; Content-based Filtering; Hybrid System

1 INTRODUÇÃO

A Internet, sem dúvidas, tornou-se uma ferramenta indispensável às pessoas neste mundo moderno. Indivíduos fazem o uso da web para atender às suas mais diversas necessidades e vontades, como fazer compras online, assistir a filmes, vídeos, séries, ouvir músicas, ler livros, revistas, notícias, participar de reuniões, trabalhar, conversar com amigos, família, assistir a aulas, entre milhares de outras atividades (Khan & Mahalakshmi, 2020). Todas estas atividades, por sua vez, são responsáveis por aumentar exponencialmente as informações contidas nas bases de dados de websites e plataformas, causando problemas de sobrecarga de dados e, conseqüentemente, tornando a busca por informações relevantes uma tarefa lenta e complicada. Para resolver esses problemas, sistemas de recomendação e ferramentas de pesquisa são propostos com o objetivo de tornar a busca por materiais relevantes uma tarefa ágil e simples (Chun-Mei et al. 2021).

Junto a isso, na última década no campo da educação, uma frequente mudança no perfil dos estudantes vem fazendo com que haja uma demanda por novos métodos de ensino e aprendizado que atendam melhor às suas necessidades e estilos de vida. Isso vem obrigando instituições acadêmicas a adaptarem seus métodos de ensino com novas tecnologias às exigências dos alunos, levando em conta também oportunidades do mundo moderno (Jordán, Botti, Turró & Valero, 2021). Além disso, a recente pandemia de Covid-19 fez com que as escolas e universidades adotassem e restringissem seus alunos a aulas online e à distância, o que mais tarde passaria a ser flexibilizado por meio do ensino híbrido (Jordán, Botti, Turró & Valero, 2021), ou seja, a

instituição proporciona todos os materiais necessários para o aprendizado à distância e, quando em sala, o aluno então tem a chance de colocar seus conhecimentos em prática.

No entanto, por mais que a criação e adoção de mais plataformas educacionais online tenham inovado a maneira de ensinar e aprender além de fazerem um bom gerenciamento de professores e alunos, ainda há uma carência de sistemas que façam recomendações personalizadas de materiais educacionais aos estudantes de modo a otimizar o seu aprendizado e aproveitando melhor o seu tempo. Além disso, por mais que o ensino online ofereça vantagens como conforto, conveniência e não ser limitado por espaço ou tempo, ele também traz novos problemas como o excesso de informações presentes em plataformas devido às inúmeras informações educacionais adicionadas todos os dias na Internet (Meng, Cheng, 2021), inflando banco de dados e dificultando a busca por materiais relevantes e que realmente agreguem ao aprendizado. Por outro lado, a falta de itens em uma plataforma acaba por limitar o aluno a poucos recursos e não permitir que conheça outras fontes e conteúdos novos.

Com os recentes avanços em tecnologias como IoT (Internet of Things), outra área que vem se tornando popular nas pesquisas são os campus universitários inteligentes ou campus inteligentes. Pontos-chave como conscientização ambiental, conexões de rede de alta performance, suporte maciço de dados, ambiente de aprendizado aberto e serviços personalizados para alunos e professores, por exemplo, são encontrados em campus inteligentes. Com o intuito de adaptar-se ao ritmo do desenvolvimento científico e tecnológico, a construção destes campus é apresentada a colégios e universidades que na tentativa de introduzir tecnologias como big data, conseguem melhorar a qualidade dos serviços educacionais, reduzir custos de serviços e atingir um gerenciamento mais eficiente (Xu, Wang & Yu, 2018). Devido a avanços na reforma do ensino superior, pessoas envolvidas no meio acadêmico estão buscando melhorias no nível de ensino de escolas e da qualidade de seus professores, exigindo cada vez mais por espaços acadêmicos mais modernos, tecnológicos, científicos e eficazes como os campus inteligentes (Xu, Wang & Yu, 2018).

A partir dos contextos apresentados, o objetivo deste artigo é modelar e desenvolver uma plataforma online que faça a recomendação de recursos educacionais como, por exemplo, cursos, mini-cursos, videoaulas, artigos científicos, palestras, eventos, teses, projetos, materiais didáticos e e-books, de maneira personalizada integrando diferentes técnicas de filtragem de dados.

O artigo está dividido em 5 seções que abordarão os seguintes tópicos: na Seção 2 são apresentados os conceitos e aplicações de sistemas de recomendação e campus inteligentes; na Seção 3 estão detalhadas as tecnologias usadas para o desenvolvimento da aplicação assim como o seu funcionamento; na Seção 4 é mostrado o processo de avaliação do algoritmo de recomendação assim como as informações dos dados presentes hoje no *dataset*; e por fim, na Seção 5 são apresentadas as conclusões desta pesquisa e perspectivas de trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção são apresentados os conceitos de sistemas de recomendação, suas aplicações e seu o contexto de criação, assim como o conceito e definições de campus inteligente, sua estrutura e recursos oferecidos.

2.1 Sistemas de recomendação

A popularização da Internet no início dos anos 90 trouxe consigo um grande número de usuários ativos, que por sua vez eram responsáveis por alimentar a rede com novos dados quase que diariamente, causando um aumento exponencial de informações em websites, redes sociais e navegadores. Além disso, permitir que inúmeros dados dos mais diversos tipos, idiomas e linguagem sejam adicionados à rede leva ao problema de heterogeneidade e complexidade de sistema, o que leva ao problema de gerenciamento e tomada de decisão em tempo real uma tarefa lenta para os usuários (Benfares, Idrissi & Abouabdellah, 2017).

De fato, selecionar e extrair informações relevantes de um determinado sistema é uma tarefa complexa, isso porque grande parte delas não é estruturada e são compartilhadas usando uma linguagem natural, ou seja, uma língua padrão não é adotada para dados na Internet, fazendo com que palavras iguais possam ser expressas de inúmeras maneiras levando à ambiguidade (Benfares, Idrissi & Abouabdellah, 2017). Um exemplo disso é a linguagem usada dentro de uma rede social e a usada para escrever artigos científicos, ou seja, por mais que as mesmas expressões possam vir a aparecer dificilmente elas terão o mesmo significado, e para um usuário que está procurando por uma informação específica pode vir a se deparar com esse caso.

Nesse contexto, é proposto como solução o uso de sistemas de recomendação (SR), que são sistemas muito voltados a pessoas que não possuem um objetivo claro sobre o que desejam pesquisar. O propósito desses sistemas baseia-se no histórico de comportamento do usuário, nos seus interesses ou em características demográficas de um grupo de usuários para gerar uma lista de itens os quais o usuário pode vir a se interessar (Chun-Mei et al. 2021). Os SR realizam previsões sobre as preferências de um usuário diante de um grande número de itens por meio do agrupamento de informações de outros usuários ou itens, dependendo do tipo de algoritmo que é implementado no sistema, tornando esses sistemas ferramentas extremamente úteis e práticas para fazer previsões personalizadas (Mrhar & Abik, 2019). Este tipo de sistema possui inúmeras aplicações nos mais diversos campos, aparecendo em sites de vendas, notícias, aplicativos de delivery, plataformas de vídeo, filmes, séries e documentários, músicas, redes sociais, serviços, sites de empregos, aplicativos de geolocalização com pontos turísticos, sites de jogos e entretenimento, sites de relacionamento e, também, plataformas acadêmicas e voltadas para a educação.

O termo sistema de recomendação apareceu pela primeira vez em um documento de trabalho escrito por Jussi Karlgren chamado 'An Algebra for Recommendations' em 1990, onde ele discute sobre o funcionamento do processo

de recomendação de uma maneira algébrica, por meio de matrizes e vetores para cálculos de similaridade entre itens (Karlgrén, 1990). Os SR, desde a popularização de seu uso, vêm evoluindo conforme as necessidades e novas aplicações surgem. Isso é evidente visto que no início da popularização de seu uso, na chamada Web 1.0, os SR eram utilizados principalmente no comércio digital que era a principal área de pesquisa na época. Depois com a Web 2.0, os SR passaram a utilizar relações entre usuários e informações contextuais para prover recomendações diversas e mais precisas. Com a chegada da Web 3.0, o uso de aparelhos móveis e tecnologias como IoT e LocationBased Systems (LBSs) já são amplamente dissolvidos na sociedade e passam a integrar os SR com, principalmente, o dado da localização atual do usuário (Dennouni, Lancieri, Peter, & Slama, 2018).

Cada tipo de recomendador faz o uso de técnicas de filtragem e algoritmos de recomendação específicos para que melhor atendam os interesses de seus usuários. Existem 3 tipos de filtragem que são muito usadas e bastante populares em sistemas de recomendação, são elas: filtragem colaborativa, filtragem baseada em conteúdo e filtragem híbrida. Sistemas de filtragem colaborativa fazem a análise do histórico de interações de maneira singular, enquanto sistemas de filtragem baseada em conteúdo se baseiam nos atributos do perfil do usuário. Já técnicas híbridas fazem a combinação de ambos os designs (Mrhar & Abik, 2019).

2.2 Campus inteligentes

As contínuas inovações em tecnologia vêm transformando os estilos de vida das pessoas, onde o termo inteligente passa a ser muito utilizado em diversos casos como cidades inteligentes, casas inteligentes, sistema inteligente, manufatura inteligente e gerenciamento inteligente. No caso da educação, os campus também passam a receber o termo inteligente referindo-se as avançadas tecnologias de comunicação e informação usadas para aumentar a eficiência das atividades dentro da universidade (Zhang, Dong, Lu, & Yip, 2022).

O termo *smart* também pode ser tratado como uma sigla para *Self-directed* (escolas com infraestrutura baseada em nuvem), *Motivated* (profissionais com habilidades motivacionais), *Adaptative* (aulas online adaptáveis), *Resource* (desenvolvimento e uso de ferramentas digitais) e *Technology* (informações de alcance global). O significado por trás da sigla seria que a educação se torna inteligente quando alunos e professores contribuem mutuamente para o enriquecimento do aprendizado e que o ambiente de sala de aula é preenchido com recursos disponíveis na nuvem usando tecnologias de ponta para que os alunos tenham acesso a mais materiais de qualidade de modo a desenvolver melhor ainda os seus conhecimentos (Imbar, Langi, & Supangkat, 2020).

Na literatura, não existe uma definição exata do que é um campus inteligente. Em (Imbar, Langi, & Supangkat, 2020), são apresentadas definições de diferentes autores, sendo algumas delas:

Integração da vida no campus aplicado a tecnologias IoT para que se tenha elementos inteligentes presentes em serviços prestados aos *stakeholders*;

Uma recente tendência que permite universidades combinarem tecnologias inteligentes com infraestrutura para prover serviços, assistência na tomada de decisões e sustentabilidade dentro do contexto acadêmico;

São campus que conseguem gerenciar recursos internos e externos de maneira eficiente fazendo o uso de soluções inteligentes para maximizar a qualidade dos serviços e vida do campus.

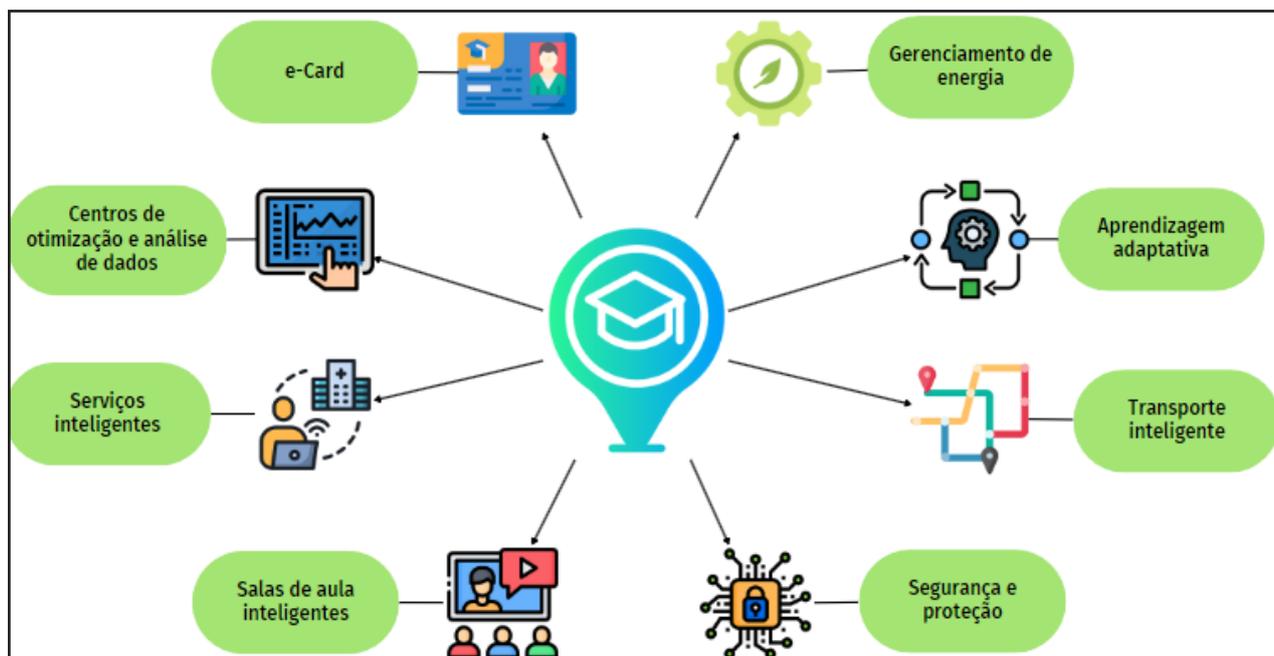
A partir dessas definições, o autor também apresenta a sua, dizendo que: “uma universidade só pode ser dita inteligente se usar de seu conhecimento para estudos, resolução de conflitos de interesse entre os usuários (alunos, professores e funcionários) e utilizar da experiência do público para contribuir com a inteligência do sistema” (Imbar, Langi, & Supangkat, 2020).

Quadro 1 – Recursos e aplicações de um campus inteligente

Critérios	Aplicações
Cartão inteligente / e-Card	Acesso às salas de aula, dormitórios e biblioteca; Carteira digital; Registro de informações e dados.
Salas de aula inteligentes	Realidade virtual e salas interativas; Aulas online; Pesquisas colaborativas.
Gerenciamento de energia	Instalações com sistema de gerenciamento de energia inteligente; Fontes de energia sustentáveis; Iluminação inteligente; Sistema de abastecimento de veículos elétricos.
Aprendizado adaptativo	Aprendizado adaptativo baseado nas necessidades do aluno/professor; Cursos e aulas suplementares.
Transporte inteligente	Estacionamento inteligente; Logística; Sinalização otimizada; Transporte interno do campus.
Segurança e proteção	Segurança e proteção de dados e sistemas.
Centros de otimização e análise de dados	Otimização de operações; Armazenamento de dados; Centros de pesquisa.
Serviços e instalações inteligentes	Quadras esportivas; Salas de estudos; Rede social do campus.

Fonte: A Strategic Framework for Smart Campus - Abualnaaj, Ahmed & Saboor, 2020

Figura 1 – Estrutura de um campus inteligente



Fonte: Autores/as (2023)

3 SISTEMA DE RECOMENDAÇÃO PROPOSTO E SUAS TECNOLOGIAS

Nesta seção são apresentadas o funcionamento das filtragens colaborativa e baseada em conteúdo, além das funções e do algoritmo usado no sistema de recomendação desenvolvido neste trabalho.

3.1 Filtragem baseada em conteúdo

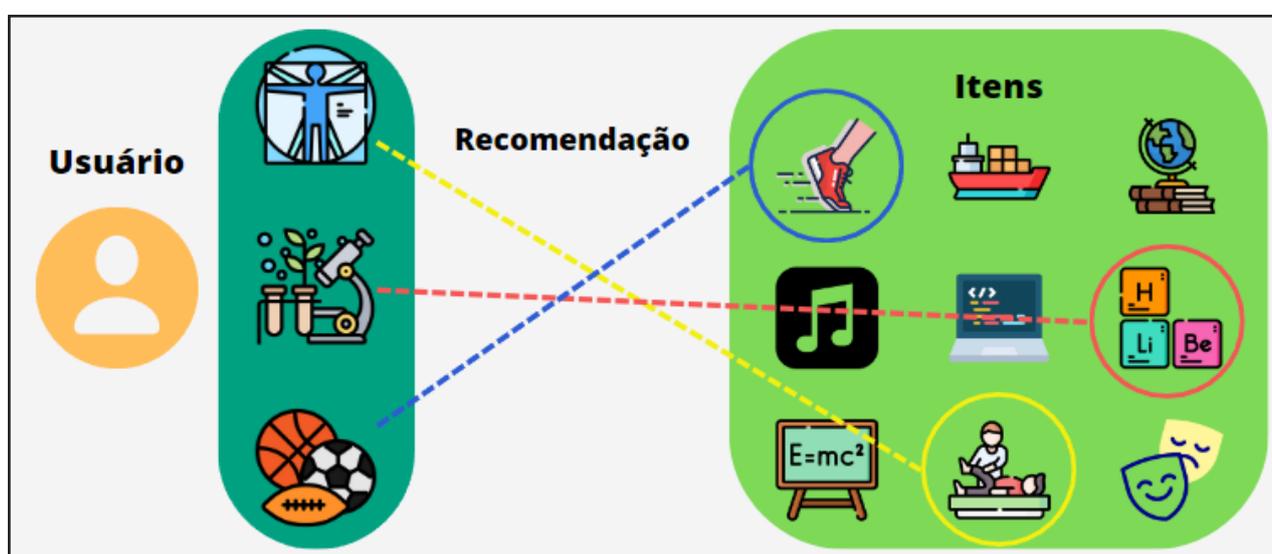
A filtragem baseada em conteúdo (*content-based filtering* - CBF) faz a recomendação de itens baseado somente no perfil do usuário, sem levar em consideração as avaliações de itens feitas por outros usuários. Dessa forma, o que essa filtragem faz é apenas extrair dados do perfil do usuário e sugerir itens baseado neles, caso haja alguma mudança nos interesses dele o algoritmo rapidamente se adapta e consegue gerar novas recomendações em um curto período de tempo.

Do ponto de vista da privacidade, a CBF pode ser muito útil aos usuários visto que não há a necessidade de tornar público os seus interesses ou suas informações de perfil, garantindo a segurança dos dados (Thannimalai & Zhang, 2021). A CBF também faz a busca por itens que são similares entre si, podendo ser filmes, músicas, livros, produtos, alimentos, entre outros. Ela procura por diferentes recursos dentro de uma base de dados e compara suas características como descrição e palavras-chave, por exemplo, e determina o quão similar são os itens para então gerar ou não a recomendação. Em sistemas que usam a CBF, não é necessário que haja dados prévios sobre algum recurso ou usuário como histórico de pesquisa, avaliações, etc., pois basta que sejam informadas as informações básicas que o algoritmo já é capaz de fazer predições. Isso faz com que os usuários de um determinado sistema passem a pensar mais sobre os seus gostos, tornando sua experiência mais agradável, pois sempre estarão recebendo recomendações do que os interessa naquele momento (Eliyas & Ranjana, 2022).

A Figura 2 apresenta um exemplo de como a CBF funciona na prática. Suponha que em uma plataforma de estudos o usuário tenha interesse nos temas anatomia,

biologia e esportes, e que no dataset dessa plataforma existam 9 itens: corrida, barcos, geografia, música, programação, química, matemática, fisioterapia e artes. Baseado nas informações dos itens e seus temas, a lista de recursos gerada pelo algoritmo incluirá os itens corrida, que está associado a esportes, química, que está associada a biologia, e fisioterapia, que está associada a anatomia. Ou seja, esses itens por apresentarem características que se relacionam diretamente com os interesses do usuário devem ser os melhores candidatos a serem recomendados ao utilizar a CBF.

Figura 2 – Ilustração da filtragem baseada em conteúdo



Fonte: Autores/as (2023)

Algumas das vantagens de se utilizar a CBF em sistemas de recomendação (Eliyas & Ranjana, 2022):

- Transparência em relação ao funcionamento do sistema;
- Vantajoso para novos usuários, pois não necessita de informações prévias, apenas seus interesses;
- Não é necessário que haja milhares de informações para se gerar recomendações;
- Novos itens já podem ser recomendados.
- E também algumas das desvantagens dessa filtragem (Eliyas & Ranjana, 2022):

- Pode ser mais limitado na questão de qualidade de recursos;
- Não é tão eficiente com *datasets* maiores;
- Pode levar mais tempo para gerar recomendações mais precisas quando o algoritmo faz o uso de mais parâmetros.

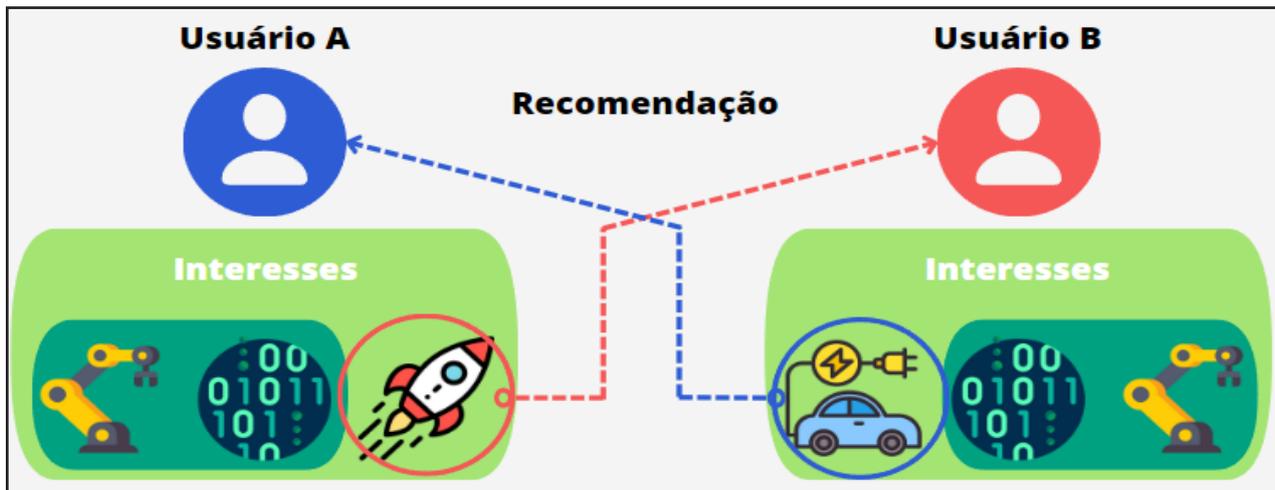
3.2 Filtragem colaborativa

A ideia principal dos algoritmos que usam a filtragem colaborativa (*collaborative filtering* - CF) é fazer a recomendação de itens para um usuário de acordo com suas relações de similaridade com outros usuários ou itens (Zheng, Wang, Wu, Yang & Zheng, 2020). Esse tipo de filtragem faz previsões sobre os interesses do usuário de acordo com as preferências, gostos e avaliações de um grande grupo de outros usuários assumindo que se outras pessoas demonstraram interesse por um determinado produto, é provável que outro usuário com interesses similares também demonstre. Por isso ela é chamada de colaborativa ou também filtragem social (Eliyas & Ranjana, 2022).

A Figura 3 apresenta um exemplo do funcionamento da CF, onde o Usuário A tem interesse em temas como robótica, programação e foguetes, e o Usuário B tem interesse em temas robótica, programação e veículos elétricos. É possível perceber que existe uma grande similaridade entre esses usuários, pois ambos compartilham de dois mesmos interesses, portanto, eles são usuários bastante similares entre si. Dessa forma, o algoritmo pode supor que recomendações sobre foguetes ao Usuário B e recomendações sobre veículos elétricos ao Usuário A terão uma alta probabilidade de acertar os seus interesses.

Já na Figura 4, está disposta uma matriz com 3 usuários e 5 recursos onde são registradas as avaliações de cada usuário diante de algum dos itens disponíveis. O algoritmo, portanto, baseado nos dados de interação de gostei, não gostei ou não avaliado de cada recurso, poderá então fazer previsões sobre possíveis gostos de usuários similares ao recomendá-los itens avaliados por indivíduos próximos dentro da matriz.

Figura 3 – Ilustração da filtragem colaborativa



Fonte: Autores/as (2023)

Figura 4 – Matriz de avaliações

Fonte: Autores/as (2023)

Algumas das vantagens de se utilizar a filtragem colaborativa são (Eliyas & Ranjana, 2022):

- Simples implementação do sistema de recomendação;
- Novos dados podem ser adicionados facilmente por qualquer usuário;
- Performance das previsões bastante eficaz;

- Os dados são coletados diretamente do usuário e, conseqüentemente, informações mais confiáveis são geradas;
- Os algoritmos são bastante portáteis e podem ser implementados em curtos períodos de tempo.
- Algumas limitações que a filtragem colaborativa apresenta são (Eliyas & Ranjana, 2022):
- São necessárias muitas informações prévias para gerar boas recomendações;
- Problema de *Cold Start*, ou seja, poucos itens no *dataset* dificultam as previsões de recomendação.

Devido às grandes quantidades de dados necessários, há um maior tempo de processamento por conta da complexidade das matrizes.

3.2.1 Filtragem colaborativa baseada em usuário (UBCF)

Nesse tipo de CF, os usuários são agrupados baseados no que eles gostam e em sua forma de agir. Cada indivíduo dentro desse grupo recebe sugestões de recursos a partir do que os usuários ao seu entorno têm preferência, utilizando o perfil, os interesses e comportamento como parâmetros para calcular a similaridade entre os indivíduos (Eliyas & Ranjana, 2022). A UBCF inclui os seguintes pontos-chave para a recomendação:

- Usuários que possuem informações de avaliações idênticas ao usuário requerente;
- Previsões para o usuário ativo são feitas baseado nas avaliações de usuários similares.

3.2.2 Filtragem colaborativa baseada em item (IBCF)

Nesse tipo de CF, é calculada a similaridade entre itens e são recomendados aqueles que apresentarem uma maior compatibilidade. Para esse tipo de filtragem, as preferências do usuário são agrupadas utilizando tanto interações implícitas (histórico de interações, taxa de acessos em itens) quanto explícitas (avaliações de itens) (Eliyas

& Ranjana, 2022). A IBCF inclui os seguintes pontos-chave para a recomendação:

- Relação entre itens representada em uma matriz de item-item;
- Combinação da matriz item-item com as informações do usuário e seus gostos para gerar recomendações.

3.3 Plataforma de recomendação

A plataforma de recomendação foi desenvolvida utilizando as filtragens colaborativa e baseada em conteúdo, criando assim um sistema de recomendação híbrido, no qual as recomendações são computadas por duas ou mais técnicas de filtragem. Ao fazer o uso da estratégia híbrida, busca-se aproveitar as vantagens que cada filtragem pode oferecer em particular e, também, contornar as limitações que elas enfrentam (Jordán, Botti, Turró, & Valero, 2021). Para a construção da plataforma foram utilizadas as seguintes tecnologias: o framework Angular para a aplicação frontend; as linguagens de programação Python e SQL para o desenvolvimento do backend; e PostgreSQL como banco de dados.

O objetivo do projeto é desenvolver uma plataforma voltada à recomendação de recursos educacionais, ou seja, videoaulas, cursos, mini-cursos, professores, projetos, eventos, publicações, pesquisas, artigos científicos, teses, materiais didáticos, e-books e todo tipo de material acadêmico que possa agregar no processo de aprendizagem de alunos, auxiliar no desenvolvimento de projetos de pesquisa e servir como ferramenta para a resolução de conflitos de interesse. Dessa forma, espera-se que a implementação desse sistema em universidades possa contribuir para o desenvolvimento dos campus universitários inteligentes.

A plataforma de recomendação hoje conta com 4 principais opções de interação para o usuário, sendo elas:

Página Inicial: é a primeira tela a ser visualizada pelo usuário ao entrar no sistema, além disso, nela estão dispostas as instruções para que ele informe os seus interesses para que o algoritmo possa gerar recomendações a ele.

Recomendados: é onde o usuário tem acesso aos recursos gerados pelo algoritmo de recomendação baseado em seus interesses.

Favoritos: é onde ficam armazenados os recursos os quais o usuário interagiu com a opção “Favorito”, ou seja, nesta aba os itens ficam salvos para que se possa acessá-los quando quiser.

Universidade: aba onde estão dispostos links para outros portais da Universidade Federal de Santa Maria como o Moodle, Portal do Aluno e site da própria Universidade Federal de Santa Maria.

O processo de recomendação de recursos educacionais baseia-se essencialmente em palavras-chave chamadas de “tópicos de interesse”, que abordam temas dos mais diversos tipos como Engenharia, Arquitetura, Programação, Geografia, Design, Brasil, Economia, Cultura e muitos outros. Para que um usuário receba recomendações ele deve seguir as seguintes etapas:

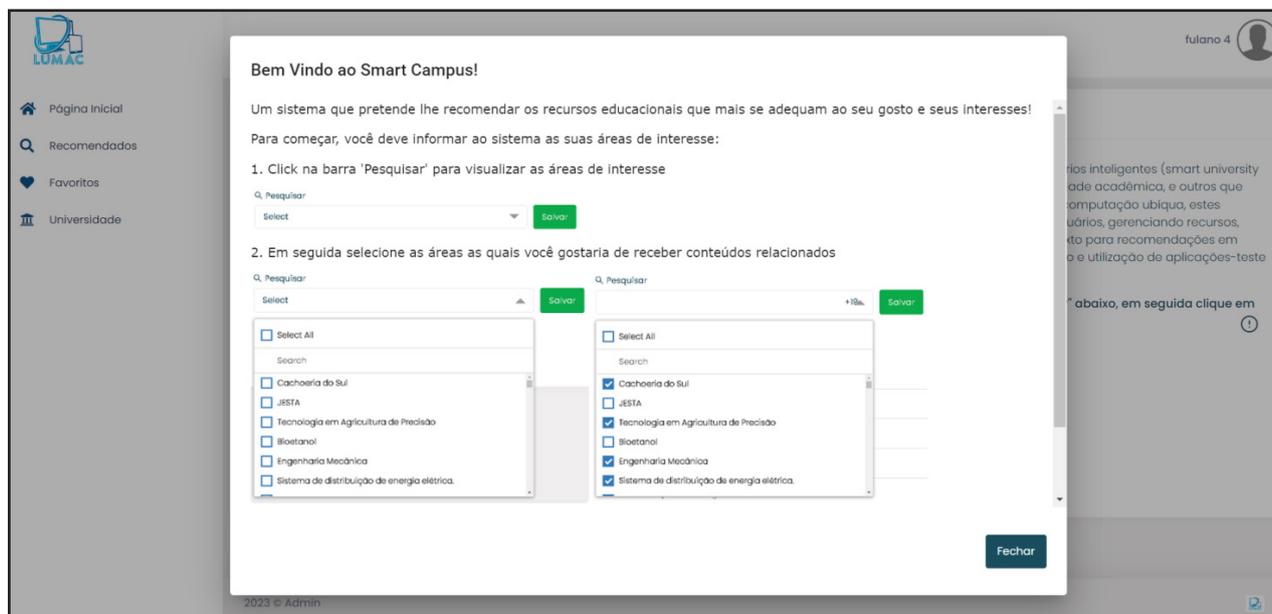
Assim que fizer o cadastro e entrar no sistema, o usuário deve seguir as instruções apresentadas na página inicial, selecionar os tópicos de interesse e salvá-los. Isso vai criar relações entre o usuário e cada tópico selecionado. A Figura 5 apresenta a tela inicial com as instruções que o usuário recebe assim que acessa o sistema.

O usuário então é redirecionado para a aba de recomendações e inicia-se o processo de filtragem. Como o algoritmo trabalha de maneira alternada entre os tipos de filtragem, será feita uma checagem para ver qual foi o tipo de algoritmo usado na última requisição do usuário para então mudar. Caso seja a primeira vez que o usuário está requisitando, será aplicado o algoritmo que usa a filtragem baseada em conteúdo.

Ao fazer a filtragem baseada em conteúdo, primeiramente, é feita uma consulta para saber se o usuário possui ou não recursos salvos nos seus “Favoritos”. Caso tenha, é feita uma busca por todos os recursos que tenham relação com seus interesses e, então, compara-se o parâmetro de texto de cada recurso encontrado com os recursos salvos, ou seja, é feita uma análise textual dos itens para determinar o quão similar eles são entre si para gerar uma lista com maior precisão e então retornar ao usuário. Caso não tenha

recursos salvos, o algoritmo simplesmente busca por recursos que tenham relação com seus interesses e os recomenda ao usuário.

Figura 5 – Tela inicial e instruções



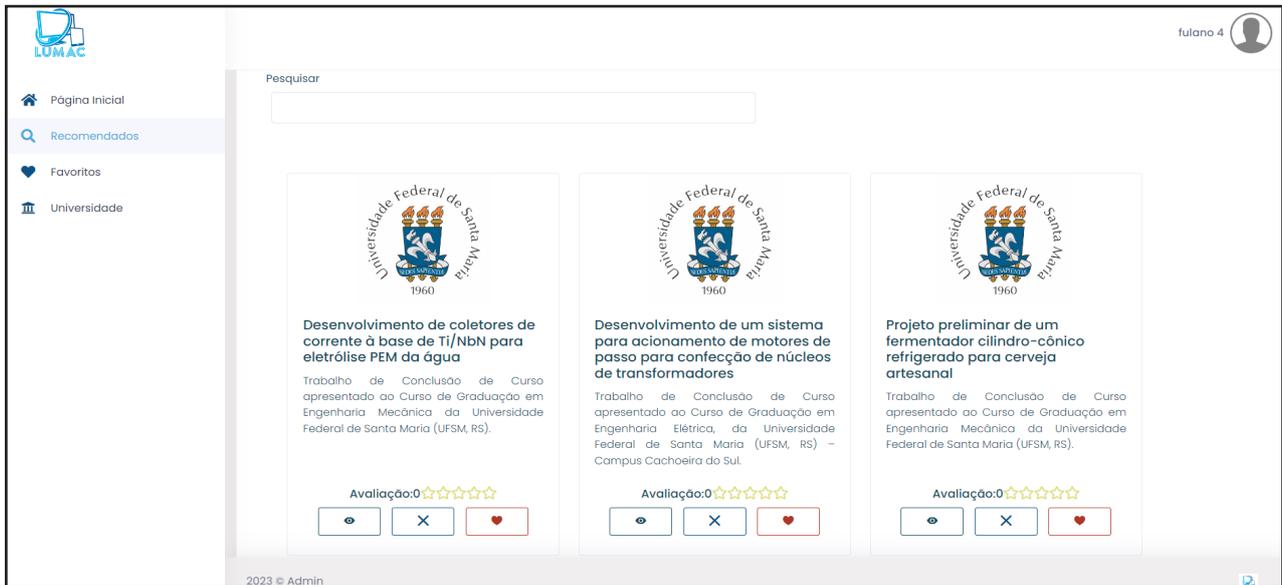
Fonte: Autores/as (2023)

Ao fazer a filtragem colaborativa, o algoritmo busca por todos os usuários que tenham interesses em comum com o requerente, faz a comparação das suas listas de tópicos de interesse e determina o nível de similaridade entre os usuários. Agora com uma lista ordenada dos usuários mais similares, o algoritmo busca pelos recursos que seriam recomendados a eles para recomendá-los ao usuário requerente.

Após o processo de filtragem, é disposto ao usuário uma lista de até 25 recursos educacionais os quais podem ser interagidos por ele. A Figura 5 mostra como são apresentados esses recursos.

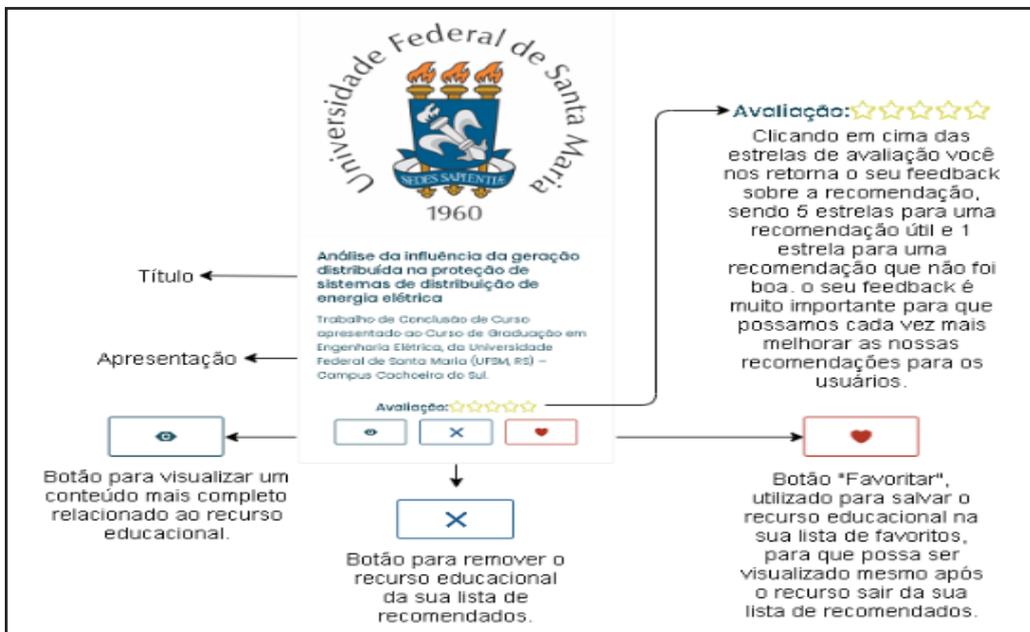
Após geradas as recomendações, o usuário pode então interagir com os itens de diferentes formas, podendo escolher entre visualizar, remover, “favoritar”/salvar ou avaliar. A Figura 7 apresenta as funções disponíveis e a descrição de cada uma.

Figura 6 – Tela de recomendados



Fonte: Autores/as (2023)

Figura 7 – Opções de interação dos recursos



Fonte: Autores/as (2023)

4 AVALIAÇÃO DO SISTEMA

Nesta seção será feito um levantamento de dados sobre o que compõe o banco de dados do sistema hoje e apresentar a avaliação de acurácia do algoritmo de recomendação.

4.1 Dataset

Para que sejam geradas as recomendações, foi necessário criar um dataset com dados relacionados ao meio acadêmico. Dessa forma, realizou-se uma pesquisa no escopo da Universidade Federal de Santa Maria por itens como artigos científicos, professores, cursos da universidade, disciplinas ofertadas, mini-cursos, cursos técnicos, videoaulas, eventos entre outros. Os itens foram identificados e scripts para a coleta de dados (*crawlers*) foram criados para importar esses recursos para a base de dados do projeto.

Quadro 2 – Relação de recursos educacionais no dataset

Categoria	Número de itens
Programa de graduação	165
Professor	135
Mini-curso	78
Dissertação de mestrado	26
Projeto de pesquisa	14
Dissertação de graduação	9
Trabalho de pesquisa	4
Projeto de extensão	2
Relatório de informações	2
Tese de PhD.	1
Publicação	1
Total	437

Fonte: Organização dos autores

O dataset hoje é composto por 189 tópicos de interesse que cobrem as mais diversas áreas de estudo da Universidade Federal de Santa Maria, além de recursos educacionais que abordam os temas dos cursos do campus de Cachoeira do Sul

(Arquitetura e Urbanismo, Engenharia Agrícola, Engenharia Elétrica, Engenharia Mecânica e Engenharia de Transportes e Logística). A relação dos recursos educacionais é mostrada na Tabela 2.

4.2 Avaliação do algoritmo

Para a avaliação da acurácia do algoritmo, inicialmente, foram criados usuários e recursos educacionais fictícios. Para os recursos educacionais, foram criados 10 os quais cada um foi relacionado com um dos tópicos da Tabela 3.

Quadro 3 – Tópicos de interesse criados para teste

ID	Tópico
0	Engenharia
1	Matemática
2	Ciências
3	Artes
4	Música
5	Esporte
6	História
7	Geografia
8	Literatura
9	Filosofia

Fonte: Organização dos autores

Para os usuários, foram criadas quantidades aleatórias entre 20 e 100 para cada tópico de interesse e quantidades aleatórias também entre 20 e 100 para cada par de tópicos de interesse. A Tabela 4 apresenta como ficaram divididos os usuários para cada tópico ou par de tópicos.

A partir da Tabela 4, é evidente que existe uma relação entre usuários que possuem interesse em Engenharia e usuários que possuem interesse em Artes, Ciência, Matemática e Música. Dessa forma, é esperado que o algoritmo seja capaz de identificar essas relações e recomendar recursos educacionais relacionados a esses temas para usuários que tenham interesse somente em Engenharia.

Já na Tabela 5 tem-se os resultados das recomendações baseadas na filtragem colaborativa, em ordem decrescente, dos recursos que foram recomendados aos usuários com interesse somente em Engenharia. Portanto, é perceptível que para esses usuários os tópicos mais similares ao seu foram Arte, Música, Ciência e Matemática, provando que o algoritmo é capaz de identificar os prováveis interesses de um usuário mesmo com poucas informações sobre ele.

Quadro 4 – Resultado do sorteio de tópicos e usuários

Tópicos de interesse	Número de usuários
Artes	49
Artes & Engenharia	77
Ciência	76
Ciência & Engenharia	55
Engenharia	81
Engenharia & Matemática	73
Engenharia & Música	94
Esporte	90
Filosofia	40
Geografia	52
História	66
Literatura	38
Matemática	56
Música	46

Fonte: Organização dos autores

Quadro 5 – Previsão de interesses do algoritmo de recomendação

ID usuário	Tópico
0	Engenharia
0	Artes
0	Música
0	Ciência
0	Matemática
0	Esporte
0	Filosofia
0	História
0	Literatura
0	Geografia

Fonte: Organização dos autores

5 CONCLUSÕES

A integração de tecnologias de ponta em campus universitários de modo a torná-los espaços mais adequados e eficientes para o desenvolvimento e melhora dos recursos e serviços oferecidos passa a ser cada vez mais explorada por essas instituições, visto que é uma exigência global de alunos e professores que buscam por melhores condições para um melhor aproveitamento do seu aprendizado.

O trabalho apresentado visa o desenvolvimento de uma plataforma online que faça a recomendação personalizada de recursos educacionais por meio de múltiplas técnicas de filtragem, algoritmos e bibliotecas, não só para alunos e professores, mas para o público em geral visando contribuir com os campus inteligentes. O resultado da avaliação do sistema evidencia que o algoritmo é capaz de fazer previsões precisas sobre interesses de um usuário mesmo com poucas informações sobre ele.

Como futuros objetivos, pretende-se implementar a função de avaliação de recurso por meio de um sistema de pesos baseado na nota de um usuário, adicionando mais um parâmetro a ser considerado pelo algoritmo na hora de realizar as filtrações. Com isso, espera-se que a precisão das recomendações seja ainda maiores e que os usuários possam receber recomendações de mais qualidade e que sejam compatíveis com seus interesses.

AGRADECIMENTOS

Este trabalho foi desenvolvido com o apoio financeiro do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), processos 405973/2021-7 e 306356/2020-1 e da Fundação de Amparo à Pesquisa do Estado do Rio Grande do Sul (FAPERGS), processo 21/2551-0000693-5.

REFERÊNCIAS

- Abouabdellah, A. Benfares, C., & eldrissi, Y. E. B. (2017). Recommendation semantic of services in smart city. *ACM International Conference Proceeding Series*, Part F129474.
- Abualnaaj, K., Ahmed, V., & Saboor, S. (n.d.). A Strategic Framework for Smart Campus. *Proceedings of the International Conference on Industrial Engineering and Operations Management Dubai*, UAE, March 10-12, 2020
- Chun-Mei, L., Jie-Teng, J., Shuo, D., Wei, P., Yan, Q., & Yi-Han, M. (2021). Personalized Recommendation Algorithm for books and its implementation. *Journal of Physics: Conference Series*, 1738(1).
- Dennouni, N., Lancieri, L., Peter, Y., & Slama, Z. (2018). Towards an incremental recommendation of POIs for mobile tourists without profiles. *International Journal of Intelligent Systems and Applications*, 10(10), 42–52.
- Eliyas, S., & Ranjana, P. (2022). Recommendation Systems: Content-Based Filtering vs Collaborative Filtering. 2022 2nd International Conference on Advance Computing and Innovative Technologies in Engineering, ICACITE 2022, 1360–1365.
- Imbar, R. V., Langi, A. Z. R., & Supangkat, S. H. (2020, November 19). Smart Campus Model: A Literature Review. 7th International Conference on ICT for Smart Society: AIoT for Smart Society, ICISS 2020 - Proceeding.
- Jordán, J., Botti, V., Turró, C., & Valero, S. (2021). Using a hybrid recommending system for learning videos in flipped classrooms and moocs. *Electronics (Switzerland)*, 10(11).
- Karlgren, J. (1990). An Algebra for Recommendations An Algebra for Recommendations Using Reader Data as a Basis for Measuring Document Proximity.
- Khan, N. Z. A., & Mahalakshmi, R. (2020). A novel user review-based contextual recommender system. *International Journal of Modeling, Simulation, and Scientific Computing*.
- Meng, H., & Cheng, Y. (2021). Research on Key Technologies of Intelligent Recommendation Based Online Education Platform in Big Data Environment. *ACM International Conference Proceeding Series*, 638–645.
- Mrhar, K., & Abik, M. (2019). Toward a deep recommender system for MOOCs platforms. *ACM International Conference Proceeding Series*, 173–177.
- Thannimalai, V., & Zhang, L. (2021). A CONTENT BASED AND COLLABORATIVE FILTERING RECOMMENDER SYSTEM. *Proceedings - International Conference on Machine Learning and Cybernetics*, 2021-December.
- Xu, X., Wang, Y., & Yu, S. (2018). Teaching performance evaluation in smart campus. *IEEE Access*, 6, 77754–77766.
- Zhang, Y., Dong, Z. Y., Lu, E., & Yip, C. (2022). A Systematic Review on Technologies and Applications in Smart Campus: A Human-Centered Case Study. In *IEEE Access* (Vol. 10, pp. 16134–16149).

Zheng, K., Wang, Y., Wu, Y., Yang, X., & Zheng, X. (2020). Collaborative filtering recommendation algorithm based on variational inference. *International Journal of Crowd Science*, 4(1), 31–44.

Contribuições de Autoria

1 – Vinícius Maran

Doutorado em Computação pela Universidade Federal do Rio Grande do Sul

<https://orcid.org/0000-0003-1916-8893> • viniciusmaran@gmail.com

Contribuição: Conceituação, Metodologia, Software, Validação, Curadoria de dados, Análise Formal, Investigação, Recursos, Curadoria de Dados, Escrita – Primeira Redação Escrita – Revisão e Edição, Visualização de dados, Supervisão, Administração do Projeto, Obtenção de Financiamento

2 – Martin Hideki Mensch Maruyama

Graduando em Engenharia Mecânica

<https://orcid.org/0000-0002-2606-581X> • martin.maru@hotmail.com.br

Contribuição: Conceituação, Metodologia, Software, Validação, Curadoria de dados, Análise Formal, Investigação, Recursos, Curadoria de Dados, Escrita – Primeira Redação Escrita – Revisão e Edição, Visualização de dados

3 – Luan Willig Silveira

Graduando em Engenharia Elétrica

<https://orcid.org/0000-0002-0187-3554> • luan.w.silveira@gmail.com

Contribuição: Conceituação, Metodologia, Software, Validação, Curadoria de dados, Análise Formal, Investigação, Recursos, Curadoria de Dados, Escrita – Primeira Redação Escrita – Revisão e Edição, Visualização de dados

Como citar este artigo

Maruyama, M. H. M., Silveira, L. W. & Maran, V. Aplicação de Técnicas de Recomendação de Recursos Educacionais em um Campus Universitário, *Ciência e Natura*, Santa Maria, v. 45, e16, 2023. DOI 10.5902/2179460X75195. Disponível em: <https://doi.org/10.5902/2179460X75195>.