



**INSTITUTO FEDERAL DE ALAGOAS
UNIVERSIDADE ABERTA DO BRASIL
CAMPUS ARAPIRACA
PÓS-GRADUAÇÃO LATO SENSU EM DOCÊNCIA PARA A EDUCAÇÃO
PROFISSIONAL E TECNOLÓGICA**

DAMARES DA SILVA CAVALCANTE

**RecomendaTEC: um sistema de recomendação para o auxílio de estudantes do ensino
médio na escolha de um curso na educação profissional e tecnológica**

ARAPIRACA, AL

2023

■

DAMARES DA SILVA CAVALCANTE

RecomendaTEC: um sistema de recomendação para o auxílio de estudantes do ensino médio na escolha de um curso na educação profissional e tecnológica

Trabalho de Conclusão de Curso (TCC) apresentado à Pós-Graduação Lato Sensu em Docência para a Educação Profissional e Tecnológica, do Instituto Federal de Alagoas, em parceria com a Universidade Aberta do Brasil, Campus Arapiraca, como requisito parcial para a obtenção do título de especialista em Docência para a Educação Profissional e Tecnológica.

Orientador(a): Prof. Dr. Maurício Vieira Dias Júnior

ARAPIRACA, AL

2023



Dados Internacionais de Catalogação na Publicação
Instituto Federal de Alagoas
Campus Arapiraca

C376r

Cavalcante, Damares da Silva.

RecomendaTEC: um sistema de recomendação para o auxílio de estudantes do ensino médio na escolha de um curso na educação profissional e tecnológica / Damares da Silva Cavalcante. – 2023.

1 PDF: il., color., (1 arquivo: 919 kB).

Arquivo digital no formato PDF do trabalho acadêmico com 51 folhas.

Orientação: Prof. Dr. Maurício Vieira Dias Júnior.

Trabalho de Conclusão de Curso (especialização, Pós-graduação em Docência para a Educação Profissional e Tecnológica) – Instituto Federal de Alagoas, *Campus Arapiraca*, Arapiraca, 2023.

1. Sistemas de recomendação - informática. 2. Educação – ensino técnico. 3. Inteligência artificial. I. Título.

CDD: 006

Luciete Barbosa da Silva
Bibliotecária CRB-4/1739

DAMARES DA SILVA CAVALCANTE

RecomendaTEC: um sistema de recomendação para o auxílio de estudantes do ensino médio na escolha de um curso na educação profissional e tecnológica

Trabalho de Conclusão de Curso (TCC) apresentado à Pós-Graduação Lato Sensu em Docência para a Educação Profissional e Tecnológica, do Instituto Federal de Alagoas, em parceria com a Universidade Aberta do Brasil, Campus Arapiraca, como requisito parcial para a obtenção do título de especialista em Docência para a Educação Profissional e Tecnológica.

Aprovada em: 13 / 12 / 2023 .

BANCA EXAMINADORA

Documento assinado digitalmente



MAURICIO VIEIRA DIAS JUNIOR

Data: 30/01/2024 10:38:11-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr. Maurício Vieira Dias Júnior (Orientador/a)

Instituto Federal de Alagoas – IFAL

Documento assinado digitalmente



WALKER ARAUJO ATAIDE

Data: 26/02/2024 18:00:06-0300

Verifique em <https://validar.iti.gov.br>

Prof. Me. Walker Araújo Ataide

Instituto Federal de Alagoas – IFAL

Documento assinado digitalmente



ROSIVANIA SILVA BEZERRA

Data: 06/03/2024 20:54:00-0300

Verifique em <https://validar.iti.gov.br>

Prof. Esp. Rosivânia Silva Bezerra Gois

Instituto Federal de Alagoas – IFAL

AGRADECIMENTOS

Agradeço a Deus, que me deu força e resiliência para concluir este trabalho.

Agradeço a mim, pela força e persistência para conclusão deste trabalho.

Agradeço ao meu orientador, o professor Dr. Maurício, pela orientação e compreensão mesmo quando eu não cumpria com as expectativas.

Agradeço também aos demais professores e tutores que me acompanharam durante a pós-graduação, cujo os conhecimentos transmitidos foram essenciais para minha formação.

Agradeço a todos que de alguma forma fizeram parte da minha jornada.

“Você precisa fazer aquilo que pensa que não é capaz de fazer.”

Eleanor Roosevelt

RESUMO

No mundo globalizado em que vivemos, a quantidade de informações acessíveis tornaram-se infinitas em conteúdo, modalidade e formas de acesso. O processo de escolha em meio a tantas opções torna-se humanamente dificultoso, por isso, surgiram formas de filtros tanto nos mecanismos de busca online quanto nas plataformas de hospedagens de conteúdos textuais e multimídia. O estudo das melhores possibilidades de aprendizagem dos alunos é um campo presente dentro da problemática da Psicologia Educacional. Os sistemas de recomendação (SR) começaram a ganhar espaço dentro do âmbito da educação pela possibilidade de trazer vantagens para os estudantes sob diferentes aspectos. A saída de estudantes do ensino médio para o ensino técnico profissional de nível técnico ou superior torna-se um desafio, dado que a escolha de uma área de atuação implica em uma escolha que irá gerar repercussão em toda a sua vida. O objetivo geral da pesquisa é propor um modelo SR para a escolha de cursos para auxiliar os estudantes a tomarem uma melhor decisão com base em características extrínsecas e intrínsecas ao aluno. A pesquisa utilizará dados do histórico escolar de todo o ensino básico dos alunos e um questionário de perfil baseado no modelo *Realistic-Investigative-Artistic-Social-Enterprising-Conventional* (RIASEC). O SR utilizará os algoritmos de filtragem baseada em conteúdo e filtragem colaborativa. Como trabalhos futuros, pretende-se implementar o modelo para o desenvolvimento de uma ferramenta para aplicação com dois níveis de estudantes: (1) estão cursando o ensino médio; e (2) estudantes que acabaram o ensino médio há mais de 1 ano. Com os resultados da aplicação será possível determinar o nível de efetividade da solução proposta.

Palavras-chave: Educação; Ensino a Distância; sistemas de recomendação; ensino técnico; Inteligência Artificial.

ABSTRACT

In the globalized world in which we live, the amount of accessible information has become infinite in content, modality and forms of access. The process of choosing among so many options becomes humanly difficult, which is why forms of filters have emerged both in online search engines and in textual and multimedia content hosting platforms. The study of students' best learning possibilities is a field present within the issues of Educational Psychology. Recommender systems began to gain space within the scope of education due to the possibility of bringing advantages to students in different aspects. The departure of high school students to professional technical education at a technical level or higher becomes a challenge, given that choosing an area of activity implies a choice that will have repercussions throughout their lives. The general objective of the research is to propose a recommendation system model for choosing courses to help students make better decisions based on extrinsic and intrinsic characteristics of the student. The research will use data from students' entire basic education records and a profile questionnaire based on the RIASEC model. The recommendation system will use content-based filtering and collaborative filtering algorithms. As future work, we intend to implement the model for the development of a tool for application with two levels of students: (1) they are attending high school; and (2) students who completed high school more than 1 year ago. With the results of the application, it will be possible to determine the level of effectiveness of the proposed solution.

Keywords: Education; Distance learning; recommendation systems; technical education; Artificial intelligence.

LISTA DE QUADROS

QUADRO 1	Comparativo	entre	trabalhos	
-	relacionados.....			33
QUADRO 2	Resultado do SR para o Eixo Tecnológico de Nível			
-	Técnico.....			41
QUADRO 3	Resultado do SR para o Ensino			
-	Superior.....			41
QUADRO 2	Resultado do SR para o Eixo Tecnológico de Nível			
-	Superior.....			42

LISTA DE FIGURAS

FIGURA 1 -	Modelagem do algoritmo de filtragem baseada em conteúdo.....	22
FIGURA 2 -	Modelagem do algoritmo de filtragem colaborativa.....	23
FIGURA 3 -	Diagrama Arquitetural do RecomendaTEC.....	35
FIGURA 4 -	Modelo de Entidade-Relacionamento para dados do Histórico Escolar.....	36
FIGURA 5 -	Modelo de Entidade-Relacionamento para Dados do Questionário de Perfil.....	37
FIGURA 6 -	Modelo do Processo de Coleta de Dados.....	38
FIGURA 7 -	Modelo do Processo de Tomada de Decisão.....	39
FIGURA 8 -	Assertivas do Modelo RIASEC.....	40

LISTA DE SIGLAS E ABREVIATURAS

EMAPRE-U	Escala de Motivação para Aprendizagem de Universitários
EAD	Educação a Distância
RV	Realidade Virtual
RA	Realidade Aumentada
NVDA	<i>NonVisual Desktop Access</i>
IA	Inteligência Artificial
ChatGPT	<i>Chat Generative Pre-trained Transformer</i>
FC	Filtros Colaborativos
RIASEC	<i>Realistic-Investigative-Artistic-Social-Enterprising-Conventional</i>
SII	Strong Interest Inventory
IFI	Inventário de Forte Interesse
OCEAN	<i>Openness-Conscientiousness-Extraversion-Agreeableness-Neuroticism</i>
AVA	Ambiente Virtual de Aprendizagem
RSL	Revisão Sistemática da Literatura
IAED	Inteligência Artificial na Educação
EA	Estratégia de Aprendizagem
CRISP – DM	<i>Cross Industry Standard Process for Data Mining</i>
KDD	<i>Knowledge Discovery Database</i>
URL	<i>Uniform Resource Locator</i>
XML	<i>Extensible Markup Language</i>
Uninassau	Centro Universitário Maurício de Nassau
SisREA	Sistema de Recomendação de Estratégias de Aprendizagem Baseado no Perfil de Motivação do Aluno
CTR	<i>Click-Through Rate</i>

SUMÁRIO

1 INTRODUÇÃO	13
1.1 Contextualização e Motivação	13
1.2 Delimitação do Problema de Pesquisa	14
1.3 Objetivos	14
1.3.1 Objetivo Geral	14
1.3.2 Objetivos Específicos	15
1.4 Relevância e Contribuições	15
1.5 Organização do Trabalho	15
2 FUNDAMENTAÇÃO TEÓRICA	16
2.1 Tecnologia na Educação	16
2.2 SR	19
2.2.1 Introdução aos SR	19
2.2.2 Modelagem matemática de um sistema de recomendação	21
2.2.3 Filtragem Baseada em Conteúdo	21
2.2.4 Filtragem Colaborativa	23
2.2.4.1 Coeficiente de Similaridade e Cálculo de Predição	24
2.3 SR para Fins Educacionais	25
2.3.1 Contexto histórico	25
2.4 Modelos de Identificação de Perfil Profissional	25
2.4.1 Modelo Realistic-Investigative-Artistic-Social-Enterprising-Conventional (RIASEC)	25
2.4.2 Strong Interest Inventory (SII)	27
2.4.3 Big Five Personality Traits	28
3 TRABALHOS RELACIONADOS	29
4 SOLUÇÃO PROPOSTA: RecomendaTEC	33
4.1 Contextualização e Descrição da Proposta	33
4.2 Visão Geral da Arquitetura	34
4.3 Modelo de Dados	35
4.4 Processo de Coleta de Dados	37
4.5 Processo de Tomada de Decisão	38
5 CONCLUSÃO	43
6 TRABALHOS FUTUROS	45
REFERÊNCIAS	46

1 INTRODUÇÃO

1.1 Contextualização e Motivação

No mundo globalizado em que vivemos, a quantidade de informações acessíveis tornaram-se infinitas em conteúdo, modalidade e formas de acesso. A enorme disponibilidade transforma o meio online em um emaranhado de informações que não conseguimos dispor de forma fácil para transformá-la em conhecimento (Cazella *et al.*, 2010). O processo de escolha em meio a tantas opções torna-se humanamente dificultoso, por isso, surgiram formas de filtros tanto nos mecanismos de busca online quanto nas plataformas de hospedagens de conteúdos textuais e multimídia.

A presença de filtros simples viabilizou a busca de informações, mas ainda possuímos uma limitação que afeta todo o escopo de busca que é o tempo. Escolher bons materiais e que realmente satisfaçam as necessidades do usuário ainda encontra-se em um processo dificultoso. Nesse contexto, surgem os sistemas de recomendação (SR), que funcionam sintetizando aspectos de escolha do usuário com mecanismos avançados de filtragem para prover as informações que realmente condizem com as necessidades particulares de cada usuário (Pontes *et al.*, 2014).

Em paralelo, o estudo das melhores possibilidades de aprendizagem dos alunos é um campo presente dentro da problemática da Psicologia Educacional. Dentro dela tem-se estudos que vão desde a utilização da Teoria da Metas (Ramos *et al.*, 2020) à utilização de escalas motivacionais como a Escala de Avaliação da Motivação para Aprender do Ensino Fundamental (EMA-EF) e Escala de Motivação para Aprendizagem de Universitários - (EMAPRE-U) (Santos *et al.*, 2013; Zenorini; Santos, 2010).

Os SR começaram a ganhar espaço dentro do âmbito da educação pela possibilidade de trazer vantagens para os estudantes sob diferentes aspectos. SR podem ser utilizados dentro do contexto educacional para fornecer sugestões dentro de um objetivo específico, seja sugestão de materiais de apoio para disciplinas, como artigos, livros, arquivos de multimídia, além de sugerir opções para carreira, recomendação de grades curriculares a depender do perfil do aluno, entre muitas outras possibilidades.

1.2 Delimitação do Problema de Pesquisa

A saída de estudantes do ensino médio para o ensino técnico profissional de nível técnico ou superior torna-se um desafio, dado que a escolha de uma área de atuação implica em uma escolha que irá gerar repercussão em toda a sua vida. Muitas vezes os jovens tomam decisões frustradas ou baseadas em conselhos externos sem um acompanhamento pedagógico e psicológico ou uma ferramenta de identificação de perfil profissional adequado às suas características particulares.

Dado o aumento no abandono das salas de aula de ensino profissionalizante e superior, a pesquisa concentra-se em propor um sistema de recomendação (SR) de cursos de ensino técnico de nível médio e superior baseado em características curriculares e de personalidade do aluno para auxiliar estudantes na escolha da melhor área de atuação com base no seu perfil pessoal e acadêmico.

A pesquisa será do tipo *Design Science Research (DSR)*, a fim de desenvolver um modelo de SR como artefato da pesquisa (Pimentel *et al.*, 2020), com o objetivo de fornecer uma lista de opções de cursos mais relacionados aos aspectos observados por cada estudante. Quanto aos métodos de coleta dos dados e referências necessárias ao desenvolvimento do trabalho serão utilizadas a pesquisa bibliográfica e a teoria fundamentada em dados, também conhecida como *grounded theory*.

1.2.1 Questões de Pesquisa

- SR podem apoiar melhores decisões na escolha de cursos de nível médio técnico subsequente e superior/tecnológico por parte de estudantes do ensino médio?
- Os SR englobam as características necessárias para definir um melhor perfil de atuação para estudantes?

1.3 Objetivos

1.3.1 Objetivo Geral

O objetivo geral da pesquisa é propor um modelo de SR para a escolha de cursos para auxiliar os estudantes a tomarem uma melhor decisão com base em características extrínsecas e intrínsecas do aluno.

1.3.2 Objetivos Específicos

- _ Propor um SR de cursos tecnológicos de nível médio subsequente e superior;
- _ Auxiliar estudantes no processo de escolha de áreas de atuação com base em características pessoais;
- _ Auxiliar cursos tecnológicos de nível médio subsequente e superior a definirem o perfil dos estudantes no curso.

1.4 Relevância e Contribuições

A escolha de um curso técnico de nível médio subsequente ou tecnológico de nível superior representa uma decisão que irá repercutir em toda a vida do aluno. Caso seja uma escolha para satisfazer a vontade de pessoas externas, a chance de aumentar a insatisfação profissional a longo prazo torna-se bastante significativa. Assim, avaliar e analisar bem o perfil de cursos profissionais é de fundamental importância, uma vez que, diferentemente de cursos superiores de licenciatura e bacharelado, os cursos profissionais preparam diretamente para atuação no mercado de trabalho.

Diferentemente de sistemas de recuperação de informações como Google, Bing ou Yahoo, em que são passadas *queries* de busca e retornados um conjunto de resultados, em SR lidamos com atributos de um usuário em específico, os quais definem o perfil de preferência daquele usuário. Nesse aspecto, o *range* de resultados possíveis deve ser muito menor, uma vez que o sistema deve realizar uma busca mais assertiva.

1.5 Organização do Trabalho

Os demais capítulos deste trabalho estão organizados da seguinte forma:

Capítulo 2 - Neste capítulo são apresentados o referencial teórico que serviu como base da pesquisa, os conceitos necessários ao entendimento do trabalho;

Capítulo 3 - Neste capítulo são apresentados os trabalhos relacionados com a pesquisa efetuada neste trabalho, destacando as semelhanças e diferenças entre eles;

Capítulo 4 - Neste capítulo é apresentado o modelo do sistema de recomendação e os aspectos relacionados à implementação do modelo;

Capítulo 5 - Neste capítulo são apresentados a conclusão do trabalho e os trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Tecnologia na Educação

A tecnologia na educação é um fenômeno que tem ganhado cada vez mais relevância nas últimas décadas (Valente, 2014). Com o advento da era digital, a integração de dispositivos e recursos tecnológicos nas salas de aula tornou-se uma prática comum, transformando significativamente o processo de ensino e aprendizagem (Santos, 2009). Pensar no fenômeno educacional envolve destacar autores importantes da psicologia educacional que elicitaram pela primeira vez na história da educação os benefícios da tecnologia como importante ferramenta na construção do conhecimento.

Lev Vigotsky, foi um defensor do sociointeracionismo, que destacava a aprendizagem efetiva como fruto da interação com o outro. Dentro do contexto tecnológico em que vivemos podemos presenciar um mundo globalizado com interações facilitadas por ferramentas tecnológicas, como as redes e mídias sociais, além dos ambientes virtuais de aprendizagem (AVA) (Tori, 2016).

Na concepção de Vigotsky, não há como haver aprendizado sem mediação, dessa forma, o conceito de tutor e mediador passa a não ser mais exclusivo da Educação a Distância (EaD), com a eliminação das fronteiras entre presencial e EaD para o surgimento de um ensino híbrido ancorado por ferramentas tecnológicas.

Jean Piaget, traz trabalhos na mesma perspectiva, tratando cientificamente o processo de aprendizagem e evidenciado o uso de computador e recursos tecnológicos no auxílio da mediação pedagógica, considerando as chamadas fases de desenvolvimento (Peixoto; Araújo, 2012).

Nos trabalhos brasileiros, tem-se o autor Paulo Freire, referência teórica na formação do discurso pedagógico, que também destaca a importância do uso do computador como meio pedagógico para alcançar a autonomia do aluno. Nessa perspectiva, o aluno torna-se um sujeito ativo na sua própria aprendizagem e encontra-se com uma perspectiva de educação mais libertadora (GOMEZ, 1999).

Um dos aspectos mais impactantes da tecnologia na educação é a personalização do aprendizado. Com a ajuda de algoritmos de aprendizado de máquina e análise de dados, os educadores podem adaptar o conteúdo e a metodologia de ensino de acordo com as necessidades individuais de cada aluno. Os psicólogos John Hattie da Universidade de Auckland e Carol Dweck da Universidade de Stanford, enfatizam a importância da diferenciação para melhorar o desempenho acadêmico (Daros, 2023).

Com os estudos voltados para o campo de *mindset*¹ e criatividade, destacam-se como o uso da tecnologia pode ser fundamental nesse processo, uma vez que dispomos de diversas ferramentas que podem ser utilizadas pelos alunos de modo a permitir um esforço maior para o uso autônomo e criativo.

Além disso, a tecnologia tem ampliado o acesso à educação em todo o mundo. Plataformas de ensino online, como Coursera² e edX³, permitem que estudantes de qualquer lugar tenham acesso a cursos de instituições de renome. No Brasil, temos várias alternativas voltadas à preparatório de vestibular online como o Descomplica⁴, graduações e pós-graduações EAD como o Centro Universitário Maurício de Nassau (Uninassau)⁵, além de ambientes gamificados como o Kahoot!⁶ que podem ser utilizados por educadores para trazer uma maior dinamicidade ao conteúdo, além de focar o aluno no centro do processo educativo.

A gamificação é uma tendência na educação, onde utiliza elementos de jogos para tornar o aprendizado mais envolvente e motivador (Mcgonigal, 2012). Argumenta ainda que os jogos têm o poder de estimular a criatividade, a colaboração e a resolução de problemas, por isso, a experiência ao utilizar jogos deve ser enriquecedora e estimulante na busca por mais conhecimento.

A experiência de jogar deve ser enriquecedora e interessante, sobrepondo-se ao resultado alcançado, uma vez que o caminho percorrido durante as horas investidas na atividade é um dos principais motivos pelo qual um jogo é iniciado, desenvolvido com engajamento e finalizado (Koster, 2013).

Além disso, a tecnologia permite a criação de AVA, nos quais os alunos podem interagir e colaborar de maneira síncrona ou assíncrona. Autores como Etienne Wenger (1998) e Jean Lave (1991) exploram as teorias da aprendizagem social e situada, que são fundamentais para entender como a tecnologia pode facilitar a construção de conhecimento em comunidades virtuais.

A realidade virtual (RV) e a realidade aumentada (RA) são tecnologias emergentes que têm o potencial de revolucionar a educação, essas tecnologias podem criar ambientes imersivos que proporcionam experiências de aprendizado altamente envolventes. Nesse contexto, podemos destacar a Teoria da Aprendizagem Situada que considera a aprendizagem

¹ *Mindset* pode ser entendido como uma crença individual que faz com que as pessoas ajam do como como agem (Biedrzycki, 2022)

² <https://www.coursera.org/>

³ <https://www.edx.org/>

⁴ <https://descomplica.com.br/>

⁵ <https://www.uninassau.edu.br/>

⁶ <https://kahoot.com/>

como socialmente construída e fundamentada em situações concretas, onde o conhecimento não é abstrato e simbólico (Engelman *et al.*, 2017).

No entanto, a integração da tecnologia na educação também apresenta desafios. É necessário estar atento para considerar questões de equidade, privacidade e segurança ao implementar soluções tecnológicas nas escolas (Santaella, 2013).

Atualmente, temos diversas outras tecnologias que permitem promover um acesso mais amplo e que atinja um maior número de estudantes, incluindo estudantes com especificidades como surdos, utilizando o vLibras⁷ ou HandTalk⁸ e para cegos através de tecnologias como NVDA⁹ para Windows e Orca¹⁰ para Linux, ambos gratuitos e disponíveis na web.

Além disso, é importante lembrar que a tecnologia é uma ferramenta, não um fim em si mesma. O uso da tecnologia na educação deve estar alinhado com objetivos pedagógicos claros, e não ser utilizado apenas de forma passageira (Leite, 2021).

As vantagens do uso de ferramentas tecnológicas devem ser claras para quem está realizando a sua manipulação, para que consiga utilizar de forma concisa e aproveitando todas as potencialidades de tais ferramentas. Ao utilizar uma tecnologia em sala de aula o professor deve estar familiarizado com o que está manipulando para que consiga extrair o máximo de proveito possível e consiga tornar o ensino e aprendizagem efetivo para ambas as partes, tanto alunos como também para ele enquanto professor/tutor (Santos, 2022).

Assim, a tecnologia na educação é um campo vasto e em constante evolução, com o potencial de transformar a forma como ensinamos e aprendemos (Leite, 2021). Autores de renome têm contribuído para o entendimento desse fenômeno, destacando tanto suas oportunidades quanto seus desafios. A chave para o sucesso está na integração cuidadosa da tecnologia, sempre com o objetivo de melhorar a qualidade da educação e o acesso ao conhecimento.

A tecnologia na educação também tem o poder de tornar o aprendizado mais interativo e colaborativo (Almeida, 2003). Ferramentas de colaboração online, como o Google Workspace for Education e o Microsoft Teams, permitem que os alunos trabalhem juntos em projetos, independentemente de sua localização geográfica, destacando que a colaboração online pode estimular a criação de conhecimento coletivo.

⁷ <https://www.gov.br/governodigital/pt-br/vlibras>

⁸ <https://www.handtalk.me/br/>

⁹ <https://www.nvaccess.org/download/>

¹⁰ https://help.gnome.org/users/orca/stable/introduction.html.pt_BR

Além disso, a tecnologia facilita a avaliação e a retroalimentação. Plataformas de aprendizado online muitas vezes oferecem recursos de avaliação automatizada, economizando tempo para os educadores. Nesse aspecto, a avaliação formativa é fundamental nesse processo, no qual os alunos recebem feedback contínuo para melhorar seu desempenho (Wiliam, 2019).

Outra área de destaque na tecnologia educacional é a inteligência artificial (IA). A IA pode ser usada para personalizar a aprendizagem, automatizar tarefas administrativas e até mesmo prever o desempenho dos alunos com base em análises de dados (Tavares, 2020).

Hoje podemos visualizar o crescimento do uso de inteligências artificiais totalmente interativas e dinâmicas com o usuário (DA SILVA MONTEIRO, 2023), onde cria-se um chat entre o usuário e a máquina como o ChatGPT¹¹ e são remetidas perguntas ou afirmações a fim de criar um diálogo onde o chat possa inicialmente entender o perfil do usuário enquanto fornece respostas e resultados. No caso do usuário não gostar das opções fornecidas poderá solicitar novos resultados.

No entanto, é crucial abordar questões éticas relacionadas à tecnologia na educação, alertando sobre os perigos da tecnologia quando usada de maneira inadequada ou desconsiderando os valores humanos. A privacidade dos alunos, a segurança dos dados e a dependência excessiva da tecnologia são preocupações que os educadores devem enfrentar com cuidado (Felix *et al.*, 2022).

Assim, a tecnologia na educação é uma força transformadora que molda o futuro da aprendizagem. Autores influentes oferecem *insights* valiosos sobre como aproveitar ao máximo as oportunidades oferecidas pela tecnologia, enquanto também destacam a necessidade de abordar questões críticas. Em última análise, a tecnologia na educação é mais eficaz quando é usada de forma consciente e estratégica, com o objetivo de enriquecer a experiência de aprendizado e preparar os alunos para os desafios do século XXI.

2.2 SR

2.2.1 Introdução aos SR

Pode-se imaginar SR como uma ida ao shopping em uma determinada loja de roupas. Inicialmente sabe que se quer comprar algo, mas não se sabe exatamente o que, por isso, entra na loja e observa-se as vitrines e os manequins expostos à procura do que se quer, mas há

¹¹ <https://chat.openai.com/>

muitas opções, tanto na respectiva loja, quanto no shopping considerando todas as demais lojas (Braida, 2022).

Para otimizar o nosso tempo, pode-se recorrer a uma atendente que sabe a localização exata dos tipos de roupas que se deseja e com base nas descrições fornecidas pelo cliente, a atendente poderá localizá-las de forma mais fácil ou caso não encontre algo exatamente com as características solicitadas pelo cliente poderá recomendar peças parecidas com base nas descrições do cliente ou com base em informações anteriores de escolhas de clientes passados com gostos semelhantes ao cliente atual.

No algoritmo citado acima pode-se perceber facilmente que se está diante de uma situação de recomendação que o cliente recorreu para otimizar o seu tempo e encontrar o que desejava de forma mais fidedigna. Também pode-se observar o algoritmo aprendendo com base em cada cliente que solicita sua recomendação, pode-se inclusive utilizar recomendações semelhantes para usuários semelhantes (Cazella, 2010).

A grande diferença da loja do shopping para os dias atuais é que na internet temos infinitas possibilidades para o que quer que busquemos. Essa intensa variabilidade dificultou ainda mais o processo de escolha de determinado item seja qual for o setor de busca.

Nesse contexto, houve o surgimento de mecanismos de busca que realizavam suas pesquisas com base em um conjunto específico de possibilidades, se pensar no Google, Bing ou Yahoo e considerar a mesma *string*¹² de busca, se terá resultados diferentes sendo gerados. Cada motor de busca utiliza um conjunto diferente de algoritmos de recomendação a depender das escolhas anteriores do usuário (Geronimo, 2015).

Um SR é, portanto, um conjunto de algoritmos criados e aprimorados para reduzir o *overload*¹³ de informações que um determinado usuário recebe ao realizar uma busca (Adomavicius; Tuzhilin, 2005). As técnicas utilizadas objetivam produzir recomendações personalizadas com base no perfil de busca do usuário (Burke, 2002). Nesse aspecto, as técnicas foram aperfeiçoadas para tornar o processo de recomendação mais otimizado e garantir a entrega de valor ao usuário que buscou.

Considerando o exemplo da loja de roupas, se a vendedora recomendar algo que realmente se gosta e se compra, em outras oportunidades os clientes serão influenciados a voltar no mesmo lugar para conseguir resultados parecidos com a experiência anterior. Da mesma forma pode-se enxergar os algoritmos, eles devem ser cada vez mais preciso e utilizar

¹² *String* em Ciência da Computação refere-se a um conjunto ou cadeia de caracteres para representação como um valor textual (Rodrigues, 2017).

¹³ *Overload* significa sobrecarga de informações que um usuário recebe ao procurar um produto (Adomavicius & Tuzhilin, 2005)

camadas cada vez mais complexas de processamento de dados para entregar sempre a melhor recomendação ao usuário (Braidá, 2022).

2.2.2 Modelagem matemática de um sistema de recomendação

Um SR busca selecionar e recomendar a um determinado usuário apenas produtos que possuam os maiores graus de utilidade para este usuário, tornando o processo de recomendação cada vez mais otimizado. Adomavicius e Tuzhilin (2005) formalizaram esse problema conforme a especificação da eq. (1).

$$\forall c \in C, \quad s'_c = \max_{s \in S} u(c, s) \quad (1)$$

Nesse modelo, seja C o conjunto de todos os usuários de um determinado sistema, e seja s' o conjunto de todos os possíveis itens que podem ser recomendados. Seja u a função utilidade que mede o quão útil é um determinado item s para um usuário c . Para todo usuário c , pertencente ao conjunto de usuários C , um SR qualquer tenha o objetivo de recomendar apenas os produtos s' o qual, para um determinado usuário c , maximize a função utilidade $u(c,s)$, ou seja, possua um valor elevado de utilidade em relação aos demais produtos.

2.2.3 Filtragem Baseada em Conteúdo

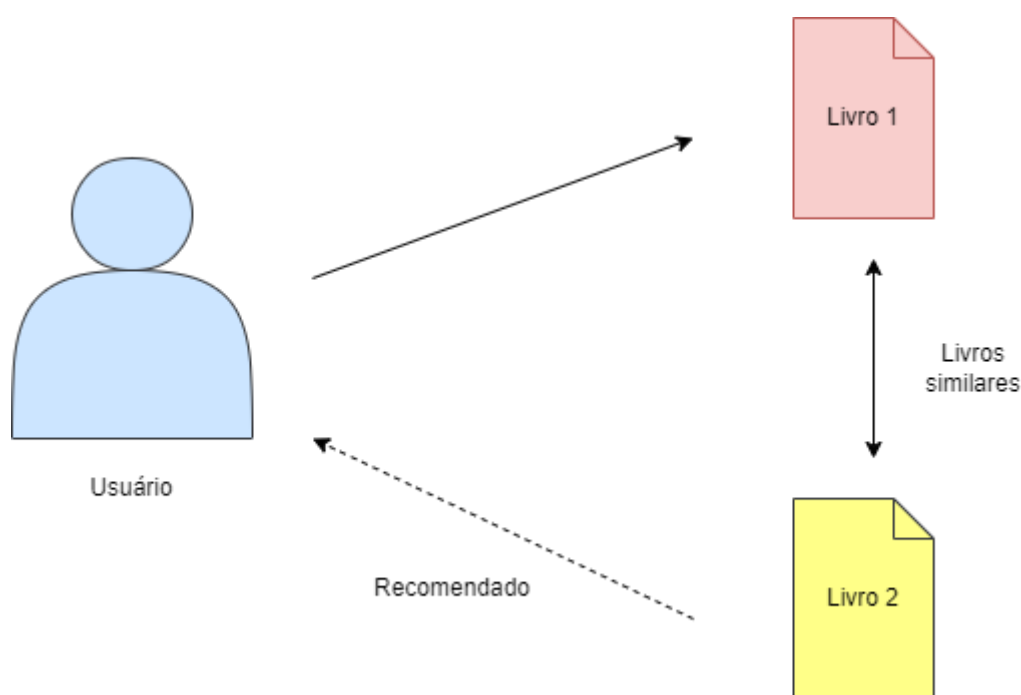
A escolha de uma determinada informação torna-se difícil em meio a tantas opções disponíveis. Com o surgimento dos SR o aperfeiçoamento das técnicas tornou-se também uma necessidade, uma vez que agora o desafio remonta para as escolhas certas aos usuários certos, passando por um processo trabalhoso de filtrar as informações adequadas. Segundo Belvin e Croft (1992) a filtragem de informação é o nome utilizado para descrever uma variedade de processos que envolvem a entrega de informação para as pessoas que realmente necessitam delas.

A filtragem baseada em conteúdo leva em consideração as descrições geradas para os conteúdos e a verificação dos interesses dos usuários nas descrições geradas. Pensar nesse tipo de algoritmo de recomendação é entender que temos de um lado produtos, objetos ou conteúdos, um algoritmo gerador de descrição para cada um, o algoritmo de recomendação que irá combinar as descrições com os interesses dos usuários e por fim os usuários que irão validar as recomendações através da aceitação ou não da recomendação gerada.

A Figura 1 representa um modelo da filtragem baseada em conteúdo, como pode-se observar está dentro de um domínio de venda/leitura de livros, onde se tem um usuário que lê um livro. Esse livro possui metadados, ou seja, dados sobre dados, que podem ser usados para comparação com os metadados de outros livros. Diante de um domínio desse tipo, tem-se um usuário que lê um livro e com base nos metadados do livro lido pelo usuário, podem ser recomendados outros livros semelhantes, como no caso da Figura 1, onde está sendo recomendado o livro 2.

Nesse modelo de recomendação, usa-se apenas os dados dos objetos de interesse ou seja os metadados dos livros ou demais produtos escolhidos por um usuário. Podemos ver isso na Netflix ou Amazon, onde com base no produto escolhido - no caso da Amazon - ou com base no filmes ou série escolhido - no caso da Netflix - possui recomendações de opções semelhantes.

Figura 1 - Modelagem do algoritmo de filtragem baseada em conteúdo.



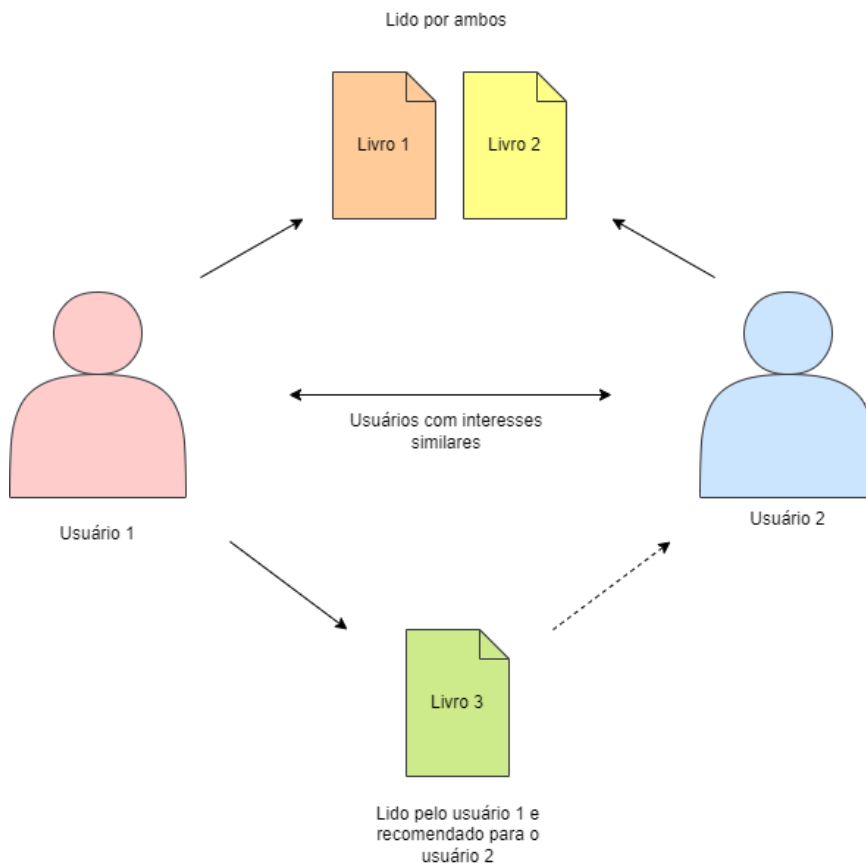
Fonte: Autora(2023)

2.2.4 Filtragem Colaborativa

A Filtragem Colaborativa constitui-se como uma das mais populares técnicas de recomendação, sendo utilizada em diversos sistemas da internet (Schafer *et al.*, 2001). Nesse tipo de abordagem de SR, os algoritmos utilizam o mecanismo similar de gostos de outros usuários para realizar recomendações específicas a outro usuário. Dessa forma, os Filtros Colaborativos (FC) constituem-se em uma técnica bem sucedida em diversas aplicações de recomendação, buscando similaridades em hábitos dos usuários para prever suas decisões futuras.

A técnica é baseada na análise de preferências comuns em grupos de pessoas, cuja a essência da técnica é a troca de experiências entre as pessoas que compartilham a mesma preferência para o uso do mesmo sistema (Cazella, 2009). A Figura 2, demonstra um modelo de filtragem colaborativa, onde tem-se o usuário 1 e 2 que leem aos livros 1 e 2, nesse contexto, o usuário 2 têm interesses similares ao usuário 1 e por essa característica tem o livro 3 que foi lido pelo usuário 1 sendo recomendado para o usuário 2.

Figura 2 - Modelagem do algoritmo de filtragem colaborativa.



Fonte: Autora (2023)

2.2.4.1 Coeficiente de Similaridade e Cálculo de Predição

O cálculo de similaridade da abordagem proposta neste trabalho utiliza o Coeficiente de Pearson, utilizado com frequência em sistemas de recomendação que utilizam a filtragem colaborativa como uma das técnicas (Cazella, 2009). O coeficiente de Pearson mede o grau de correlação entre duas variáveis resultando em valores entre $[-1;+1]$, onde o -1 representa a ausência total de correlação e o +1 representa a correlação total entre as variáveis. A eq. (2) representa o coeficiente de Pearson utilizado.

$$\rho = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \cdot \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} = \frac{cov(X,Y)}{\sqrt{var(X) \cdot var(Y)}} \quad (2)$$

O objetivo do coeficiente de Pearson no contexto da proposta é verificar a correlação entre estudantes a partir das notas e questionário de gostos submetidos anteriormente para treinamento do sistema. Calcula-se a recomendação a partir do quanto um aluno ficaria satisfeito ao receber determinada recomendação com base no seu histórico e questionário de gostos.

Além do cálculo da correlação entre os estudantes, é necessário realizar o cálculo da predição das próximas recomendações, que é realizado de forma independente do cálculo de correlação. O objetivo da predição é realizar uma média ponderada das avaliações fornecidas por estudantes de recomendações anteriores com base nos seus vizinhos próximos, ou seja, outros estudantes que tenham o mesmo perfil do que estão avaliando. A eq. (3) exibe a equação de predição que será utilizada para predição neste trabalho, baseada em Cazella *et al.* (2008).

$$p_{ai} = \overline{r_a} + \frac{\sum_{b=1}^n (r_{bi} - \overline{r_b}) * corr_{ab}}{\sum_{b=1}^n |corr_{ab}|} \quad (3)$$

Nessa equação, temos:

$corr_{ab}$ é a correlação do estudante alvo a com um determinado estudante b ;

p_{ai} , predição de um curso técnico i para um estudante alvo a ;

$\overline{r_a}$, média de todas as avaliações do estudante alvo a aos cursos técnicos que foram pontuados por todos os outros estudantes similares;

$\overline{r_{bi}}$, é a avaliação que o estudante ativo b atribuiu para o curso técnico i ;

$\overline{r_b}$, é a média de todas as avaliações do aluno b , em comum com o aluno a .

2.3 SR para Fins Educacionais

2.3.1 Contexto histórico

SR surgiram inicialmente voltados para o comércio eletrônico com objetivo de recomendar produtos para serem adquiridos (Xiao *et al.*, 2018). Devido ao contexto voltado ao comércio, houve certo atraso para que as vantagens dos SR fossem enxergadas para a educação, por isso, as pesquisas de que tratam deste tema são mais recentes.

Propor um SR voltado para o contexto histórico enseja a elicitación de novos requisitos já que o perfil de indicação muda completamente, ao invés de estarmos diante de produtos únicos temos uma variedade de itens dentro do mesmo processo de indicação, como textos, vídeos, hiperlinks, áudio, entre outros materiais do ambiente digital.

No processo de composição de SR, há amplas pesquisas na utilização de Inteligência Artificial (IA) no processo de recomendação. O uso de IAs permite um processo de filtragem muito mais robusto e complexo semelhante ao que seria realizado por um humano. Dessa forma, técnicas de implementação de sistemas de recomendação baseados em IA têm ganhado bastante relevância. Os SR auxiliam no aumento da capacidade e eficácia deste processo de indicação já bastante conhecido na relação social entre seres humanos (Resnick; Varian, 1997).

2.4 Modelos de Identificação de Perfil Profissional

2.4.1 Modelo *Realistic-Investigative-Artistic-Social-Enterprising-Conventional* (RIASEC)

O modelo RIASEC, também conhecido como *Holland Codes*, é uma estrutura de avaliação de interesses profissionais desenvolvida por John L. Holland. Holland propôs que os indivíduos têm seis tipos principais de personalidade, e esses tipos podem ser associados a ambientes de trabalho ou carreiras específicas (Armstrong, 2009). Os seis tipos são

representados pelas iniciais do modelo Realista (R), Investigativo (I), Artístico (A), Social (S), Empreendedor (E) e Convencional (C), e são descritos abaixo.

- **Realista (R)**

- Indivíduos que têm interesse em atividades práticas e físicas.
- Preferem trabalhar com coisas concretas e tangíveis.
- Gostam de atividades ao ar livre e trabalhos práticos, como construção, agricultura ou mecânica.

- **Investigativo (I)**

- Pessoas orientadas para a investigação e resolução de problemas.
- Têm interesse em atividades intelectuais e científicas.
- Podem se destacar em profissões como ciência, pesquisa, engenharia ou tecnologia.

- **Artístico (A)**

- Indivíduos criativos e expressivos.
- Têm um forte interesse em atividades artísticas e estéticas.
- Podem se destacar em carreiras como arte, design, música, teatro ou escrita.

- **Social (S)**

- Pessoas que têm uma inclinação para trabalhar com outras pessoas.
- Preferem atividades que envolvam interação social e ajudar os outros.
- Carreiras relacionadas à saúde, educação, serviços sociais e aconselhamento podem ser atrativas.

- **Empreendedor (E)**

- Indivíduos que são orientados para o sucesso e a liderança.
- Têm interesse em atividades empresariais, vendas e persuasão.
- Podem se destacar em carreiras como gestão, vendas, marketing ou empreendedorismo.

- **Convencional (C)**

- Pessoas que valorizam a organização e a eficiência.
- Preferem atividades estruturadas e rotineiras.
- Podem se destacar em profissões como contabilidade, administração, secretariado ou tecnologia da informação.

É importante notar que muitos indivíduos têm uma combinação de interesses e podem se identificar com mais de um tipo. O objetivo do modelo RIASEC é proporcionar uma estrutura para ajudar os indivíduos a explorar e entender suas preferências profissionais, e orientadores de carreira muitas vezes usam esse modelo como uma ferramenta para aconselhamento vocacional.

2.4.2 Strong Interest Inventory (SII)

O SII ou Inventário de Forte Interesse (IFI) (tradução livre para o português), é um instrumento de avaliação de interesses vocacionais que ajuda os indivíduos a explorar e entender suas preferências profissionais. Ele foi desenvolvido com base na teoria dos tipos de interesse de John L. Holland, o mesmo psicólogo que propôs o modelo RIASEC. O SII é projetado para fornecer *insights* sobre as áreas de interesse de uma pessoa e como essas áreas se relacionam com diferentes campos ocupacionais (Spanierman *et al.*, 2006). Aspectos importantes sobre o SII são descritos abaixo.

- **Tipos de Interesse**

- O SII classifica os interesses das pessoas em seis categorias principais, alinhadas com os tipos de interesse de Holland: Realista, Investigativo, Artístico, Social, Empreendedor e Convencional.

- **Perfis Pessoais**

- Com base nas respostas dadas pelos indivíduos a uma série de perguntas, o SII gera um perfil de interesse pessoal. Este perfil indica a intensidade dos interesses em cada uma das seis áreas.

- **Relacionamento com Carreiras**

- O SII associa os perfis de interesse a uma ampla gama de carreiras e campos de estudo. Ele fornece informações sobre quais tipos de trabalho podem ser mais atraentes para uma pessoa com determinados interesses.

- **Concordância com Profissionais Bem-sucedidos**

- O instrumento também compara os resultados individuais com perfis de profissionais bem-sucedidos em várias áreas. Isso ajuda a destacar carreiras nas quais pessoas com interesses semelhantes geralmente encontram satisfação.

- **Uso em Processos de Orientação Profissional**

- O SII é frequentemente utilizado por orientadores vocacionais, psicólogos e profissionais de recursos humanos para orientar estudantes, profissionais em transição de carreira e outros indivíduos na exploração de opções profissionais.
- **Autoconhecimento e Tomada de Decisão**
 - Além de fornecer informações sobre carreiras específicas, o SII pode ajudar os indivíduos a desenvolverem um maior autoconhecimento, entendendo melhor seus próprios interesses e preferências.

É importante ressaltar que o SII é uma ferramenta que faz parte de um processo mais amplo de orientação e aconselhamento. Seus resultados devem ser interpretados por profissionais qualificados, e a decisão de carreira deve ser considerada em conjunto com outros fatores, como habilidades, valores pessoais e metas profissionais.

2.4.3 Big Five Personality Traits

O modelo dos **Big Five Personality Traits** ou Cinco Grandes Fatores de Personalidade (tradução livre para o português), comumente conhecido como *Big Five*, é um dos modelos mais amplamente aceitos para descrever e avaliar a personalidade humana. Esses cinco fatores representam dimensões amplas de traços de personalidade e são frequentemente referidos pelas iniciais OCEAN, que correspondem a *Openness* (Abertura), *Conscientiousness* (Consciência), *Extraversion* (Extroversão), *Agreeableness* (Amabilidade) e *Neuroticism* (Neuroticismo) (Gerber *et al.*, 2011). As características principais de cada fator estão descritas abaixo.

- **Abertura (*Openness*)**
 - Indica o grau de abertura a novas experiências e ideias.
 - Pessoas com alta pontuação em Abertura tendem a ser criativas, curiosas e abertas a novas ideias.
 - Pessoas com baixa pontuação podem preferir a rotina, ser mais tradicionais e práticas.
- **Consciência (*Conscientiousness*)**
 - Reflete o grau de organização, responsabilidade e disciplina.
 - Indivíduos altamente conscientes são geralmente organizados, planejadores e orientados para metas.
 - Pessoas com baixa pontuação podem ser mais espontâneas, menos organizadas e menos focadas em metas a longo prazo.

- **Extroversão (*Extraversion*)**
 - Indica o grau de sociabilidade, assertividade e busca por estimulação social.
 - Pessoas extrovertidas tendem a ser energizadas pela interação social, extrovertidas e expressivas.
 - Introversos, por outro lado, podem preferir ambientes mais tranquilos, serem reservados e recarregarem energia em momentos de solidão.
- **Amabilidade (*Agreeableness*)**
 - Reflete o grau de empatia, cooperação e gentileza.
 - Indivíduos altamente amigáveis são frequentemente compassivos, cooperativos e valorizam as relações interpessoais.
 - Aqueles com baixa pontuação podem ser mais críticos, competitivos e diretos.
- **Neuroticismo (*Neuroticism*)**
 - Indica o grau de estabilidade emocional e resiliência ao estresse.
 - Pessoas com pontuações mais altas em neuroticismo podem ser propensas à ansiedade, ao estresse e às variações de humor.
 - Indivíduos com baixa pontuação tendem a ser mais estáveis emocionalmente, resilientes e menos propensos a se preocupar excessivamente.

Esses traços de personalidade não são mutuamente exclusivos, e a maioria das pessoas exibe uma combinação única de cada fator. O *Big Five* é frequentemente utilizado em pesquisas psicológicas, testes de personalidade e avaliações de recursos humanos para compreender melhor o comportamento e as preferências das pessoas em diversos contextos.

3 TRABALHOS RELACIONADOS

A utilização de SR na educação é uma frente de pesquisa relativamente nova, quando comparada com o início dos sistemas de recomendação para o comércio eletrônico. O surgimento da pandemia de COVID-19 no final do ano de 2019 e o *lockdown* em quase todo o mundo a partir de 2020 resultou em uma transferência do ensino presencial para o ambiente virtual, fortalecendo ainda mais a modalidade EaD.

Diferentemente da EaD que vivenciávamos até então, com o surgimento da pandemia, os alunos e professores que sempre atuaram na modalidade presencial foram “forçados” a migrarem suas atividades de ensino para o ambiente virtual, aprendendo uma nova didática e desenvolvendo novas metodologias.

Para que essa migração pudesse ter efetividade foi necessário uma mudança no paradigma educacional, com o início de novas pesquisas científicas, desenvolvimento de novas didáticas e metodologias e o surgimento de novas tecnologias que auxiliassem o processo de ensino-aprendizagem.

No contexto de SR, há hoje diversas pesquisas que desenvolvem métodos específicos de auxílio para o aluno no processo de aprendizagem e pesquisas que também auxiliam o professor no processo de ensino e avaliação dos alunos.

Na pesquisa de Moraes Neto; Fernandes; Amiel (2020), é desenvolvido um chatbot e análise conversacional para a recomendação da aprendizagem colaborativa na EaD. O objetivo deste trabalho foi desenvolver uma pesquisa que abordasse a aprendizagem colaborativa entre estudantes através de um agente conversacional, que fomentasse um diálogo entre o aprendiz e o chatbot.

Nessa pesquisa, a partir do diálogo entre alunos e chatbot é realizada uma análise conversacional em que é possível a avaliação tanto da estrutura, como conteúdo, papéis e relacionamentos nas conversas. Na pesquisa, a análise conversacional é usada como ponto de instigação dentro de um Ambiente Virtual de Aprendizagem (AVA), em que o professor poderá avaliar em que pontos estão ocorrendo a colaboração e em que pontos está ocorrendo uma mitigação da mesma.

O trabalho de Moraes Neto; Fernandes; Amiel (2020) foi desenvolvido na forma de uma Revisão Sistemática da Literatura (RSL), tendo como questão de pesquisa principal “a adoção de agente conversacional com análise conversacional pode realizar a recomendação da aprendizagem colaborativa na EaD?”. O resultado da RSL demonstrou a escassez de trabalho que utilizem agentes conversacionais para a recomendação de aprendizagem colaborativa na EaD, mas trouxe diretrizes importantes para a aplicação de Inteligência Artificial na Educação (IAED).

Na pesquisa dos resultados do trabalho geral, encontrou-se trabalhos recentes, dos quais alguns são experimentais e alguns teóricos. No aspecto da análise conversacional, constatou-se que os trabalhos buscavam estudar como a compreensão era construída em ambientes virtuais e como as recomendações poderiam ser geradas a partir dessa compreensão.

Nos estudos, os pesquisadores utilizaram tecnologias já consolidadas na literatura de IA e aprendizagem de máquina, mas todas desenvolveram os próprios chatbots. O trabalho também destaca um ponto importante que deve ser considerado em novas pesquisas

(Aggarwal, 2016), que é o fato de as recomendações devem partir de requisitos do aprendiz e não por seu histórico de interação, que é o que se busca no desenvolvimento deste trabalho.

O trabalho de Amaral *et al.* (2021), desenvolve um SR de estratégias de aprendizagem baseado no perfil de motivação do aluno, que eles denominam de Sistema de Recomendação de Estratégias de Aprendizagem Baseado no Perfil de Motivação do Aluno (SisREA). O trabalho é desenvolvido utilizando dados do questionário EMAPRE-U, que é aplicado em um AVA chamado de CodeBench¹⁴, que gera um perfil de motivação do aluno e consegue recomendar uma estratégia de aprendizagem adequada ao perfil do estudante.

O processo do trabalho é composto de três módulos, o primeiro é o módulo do estudante que realiza a coleta de dados com base no questionário para atribuir a motivação, e há o segundo módulo de classificação da motivação. O terceiro módulo é o da recomendação que utiliza os dados de motivação e estratégias de aprendizagem registradas no sistema. Vale destacar que as estratégias de aprendizagem (EA) estão associadas às motivações.

Cada EA possui uma meta e as motivações são associadas a elas. As recomendações são enviadas para os estudantes via e-mail, e passam por um processo de avaliação representado por estrelas, assim é possível verificar se a recomendação é significativa ou não para o estudante, com o resultado avalia-se se de fato a recomendação está correlacionada com a motivação.

Para avaliação da proposta apresentada, os pesquisadores Amaral *et al.* (2021) aplicaram um questionário de forma voluntária para os estudantes. A avaliação das estratégias utilizou a escala de *Likert*, onde foi possível observar que 68% dos estudantes avaliaram a recomendação com cinco estrelas, demonstrando que as estratégias recomendadas realmente foram significativas para os alunos. Em relação, ao percentual com as demais estrelas, demonstrou que as estratégias não foram tão significativas para os alunos, podendo serem reformuladas ou retiradas do sistema.

Como ponto limitante, o trabalho conseguiu realizar a avaliação das recomendações manuais realizadas por professores, mas não conseguiu testar e avaliar as recomendações automáticas propostas no sistema. Dessa forma, não foi possível avaliar efetivamente um SR automática que utilizasse a técnica de filtragem colaborativa.

O trabalho de Oliveira *et al.* (2016), desenvolve um modelo preditivo para classificação de estudantes com retenção universitária. A retenção e a evasão é um problema que acomete diversas instituições de ensino. A retenção é caracterizada como a permanência

¹⁴ <https://codebench.icomp.ufam.edu.br/>

dos estudantes além do tempo de integralização do curso e a evasão caracteriza-se como abandono do curso.

O referencial teórico desta pesquisa aponta para um trabalho desenvolvido por um pesquisador americano chamado Tinto, que sugere que a evasão ocorre pela falta de integração do estudante com o ambiente acadêmico (Tinto, 2015).

O objetivo principal do trabalho é desenvolver um processo de mineração de dados para análise da evasão e retenção universitária, para isso, foi utilizado o processo chamado de CRISP-DM (*Cross Industry Standard Process for Data Mining*). Esse modelo é descrito na forma de processos, sendo guiado durante todo o seu ciclo de vida, desde o nível mais genérico até o nível mais específico. A vantagem de utilização da mineração de dados trazida pelo trabalho é a identificação de padrões ocultos nos dados que são inacessíveis pelas técnicas de análise tradicionais.

A análise de um grande número de variáveis é facilitada utilizando esta técnica. A extração de novos conhecimentos utiliza o KDD (*Knowledge Discovery Database*), permitindo atuar de forma interdisciplinar entre campos como Aprendizagem de Máquina, Reconhecimento de Padrões e Estatística. O CRISP-DM engloba tanto as técnicas de KDD quanto de *Data Mining*. Além disso, a técnica permite utilizar um processo recursivo, onde cada etapa pode ser revista até apresentar resultados satisfatórios.

Os dados da pesquisa foram organizados em dados de treinamento e dados de teste, e utilizada Regressão Logística. Analisando os dados produzidos pela árvore de decisão, foi possível perceber que o total de reprovações no segundo período é o principal fator que explica o jubramento dos alunos, denotando que o rendimento e a participação acadêmica nos primeiros períodos são fundamentais para a permanência do estudante no ambiente universitário.

Dessa forma, foi possível perceber através da pesquisa de Oliveira *et al.* (2016) os principais fatores relacionados à evasão de alunos, destacando a deficiência de um ambiente acadêmico acolhedor e que permita que alunos com diferentes níveis sejam capazes de atuarem juntos dentro da mesma sala de aula. Por isso, ferramentas que permitam ao aluno a interação com os demais entes do ambiente acadêmico, assim como uma ferramenta inicial que permita conduzir as escolhas do aluno para o curso de maior afinidade tornam-se relevantes.

O Quadro 1 exibe um comparativo entre os trabalhos relacionados apresentados, mostrando o objetivo, técnica de aprendizagem/tratamento de dados utilizados e limitações.

Quadro 1: Comparativo entre trabalhos relacionados

Trabalho	Objetivo	Técnicas de aprendizagem	Limitações
Moraes Neto; Fernandes; Amiel (2020)	Revisão da literatura para a adoção de agente conversacional para realizar recomendação na EaD	Aprendizagem colaborativa	Limitou-se à RSL, com trabalhos teóricos e experimentais; Não propôs modelo ou ferramenta
Amaral <i>et al.</i> (2021)	SisREA: Um SR de estratégias de aprendizagem baseado no perfil de motivação do aluno	Não implementou técnica de aprendizagem	O trabalho avaliou apenas as recomendações manuais fornecidas pelos professores
Oliveira <i>et al.</i> (2016)	Modelo preditivo para classificação de estudantes com retenção universitária	CRISP-DM (<i>Cross Industry Standard Process for Data Mining</i>)	O trabalho considerou apenas duas variáveis para classificação da retenção

Fonte: Autora (2023)

4 SOLUÇÃO PROPOSTA: RECOMENDA TEC

4.1 Contextualização e Descrição da Proposta

A proposta deste trabalho é desenvolver um modelo de SR para auxiliar estudantes do ensino médio a decidirem sua carreira profissional dentro do contexto do ensino técnico profissionalizante técnico subsequente ou de nível superior. Para isso, será utilizada a pesquisa do tipo *Design Science Research (DSR)* que consiste no desenvolvimento de um artefato de pesquisa (Pimentel *et al.*, 2020). O sistema usará dados de quatro fontes: a) boletim do ensino fundamental anos iniciais; b) boletim do ensino fundamental anos finais; c) boletim do ensino médio; e d) questionário de perfil e gostos baseado no modelo RIASEC.

Os dados coletados através dos boletins e do questionário de perfil serão utilizados como dados de entrada para o treinamento do sistema. Os dados serão inseridos manualmente para treinamento do SR.

4.2 Visão Geral da Arquitetura

A arquitetura geral do *RecomendaTec* pode ser observada na Figura 3, em que é possível visualizar todos os componentes e a interação entre eles. O SR inicia com uma ação ativa do usuário em solicitar uma recomendação com base no seu perfil. O usuário ao realizar a interação com o sistema utiliza uma interface podendo ser um aparelho de computador ou celular.

O próximo componente é o WebApp que disponibiliza ao usuário uma URL para ser acessada via navegador Web ou Mobile para acessar a interface de interação inicial. Ao acessar a URL será exibida uma página Web com informações sobre o sistema, com campos abaixo para submissão em separado do histórico do ensino fundamental anos iniciais, histórico do ensino fundamental anos finais e histórico do ensino médio. Após a submissão de cada um dos itens anteriores será realizado um pré-processamento desses dados para verificação da adequação dos dados fornecidos ao processo de coleta de dados do sistema.

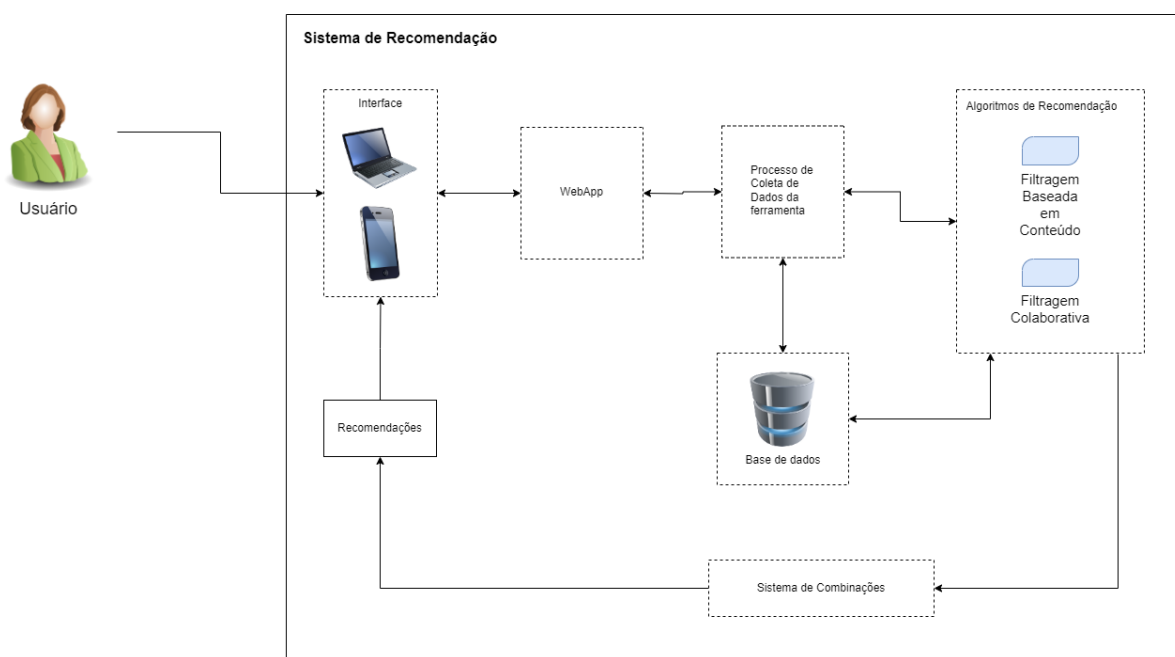
Com o pré-processamento sendo bem sucedido, será gerado um questionário de identificação de perfil vocacional baseado no modelo RIASEC. Esse modelo de questionário é composto por uma série de 48 tarefas, sendo avaliadas em uma escala que varia entre (1) nenhuma afinidade e (10) extrema afinidade. O questionário fica disponível assim que o processamento dos dados do histórico é finalizado com sucesso, assim é habilitado um botão para que o usuário inicie a realização do teste. Após finalizado, os dados são submetidos e realizada a segunda etapa do processamento dos dados.

Com a coleta de dados e o pré-processamento dos dados finalizados, é iniciado o processo de análise dos dados por meio dos algoritmos de recomendação. Inicialmente é aplicado o algoritmo de filtragem baseada em conteúdo e posteriormente o algoritmo de filtragem colaborativa.

Após aplicados os algoritmos nos dados pré-processamento, o resultado é enviado para o sistema de combinação que utiliza as duas técnicas anteriores, a análise de ambos os algoritmos retorna dois conjuntos de combinações a interseção entre os dois conjuntos é retornada para o usuário, garantindo uma maior acurácia da recomendação realizada.

As recomendações são direcionadas à interface de comunicação utilizada pelo usuário e com base no perfil de aceitação da recomendação atribui-se uma pontuação na base de dados para a recomendação realizada. Assim, o algoritmo de aprendizagem aprende constantemente com a validação dos usuários sobre as recomendações realizadas.

Figura 3: Diagrama Arquitetural do RecomendaTEC



Fonte: Autora (2023)

4.3 Modelo de Dados

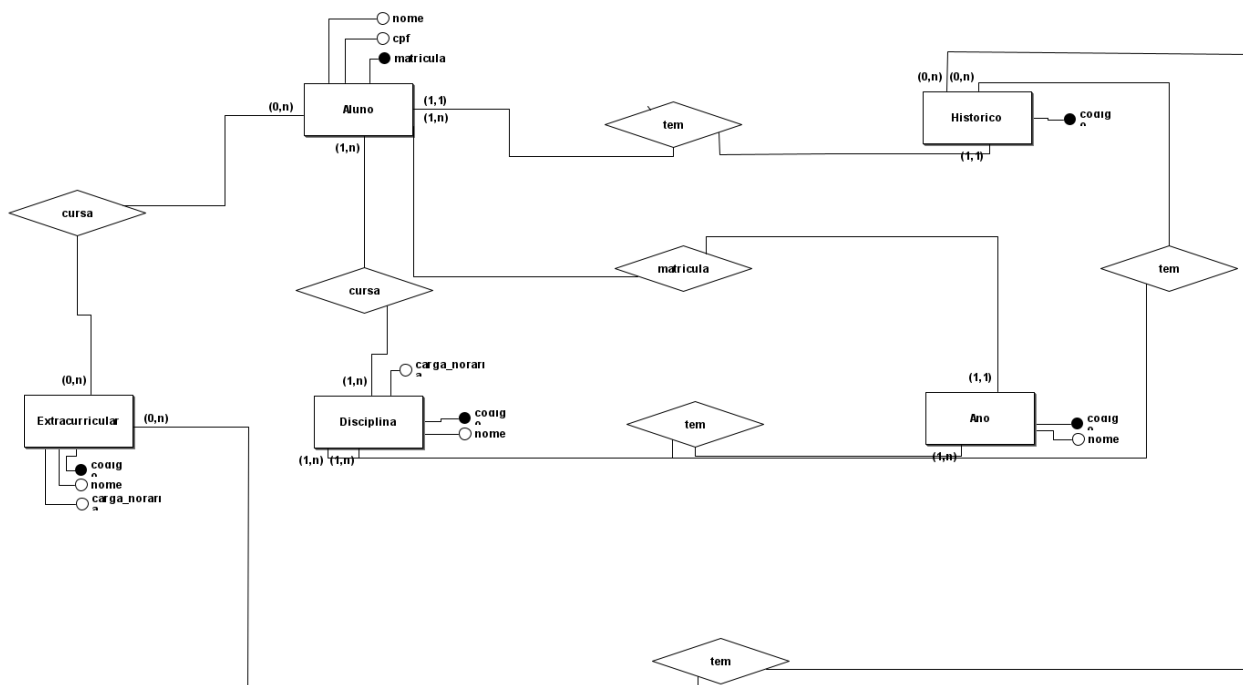
A base de dados, destacada na Figura 4, guardará as informações do histórico escolar do aluno de todo o ensino básico, bem como as atividades extracurriculares realizadas por ele. Essa base é consumida pelo combinador para gerar as recomendações com base nas especificidades dos usuários. A base de dados é alimentada pelo componente *Coletor* e pelo componente *Combinador*.

As entidades são representadas por retângulos e representam entidades do mundo real dentro do contexto de observação, que no nosso caso é escola. Os relacionamentos entre entidades são representados por losangos e os atributos das entidades são representados por círculos. Um círculo preenchido representa que aquele atributo é identificador da entidade. O intervalo entre parênteses representa a cardinalidade do relacionamento entre entidades e significa o valor mínimo e o máximo com os quais as entidades podem se relacionar. Abaixo são descritos todos os relacionamentos entre as entidades de acordo com o modelo da Figura 7.

- **Aluno-Histórico:** O aluno tem um histórico e o histórico só pode ser de um aluno;
- **Aluno-Ano:** O aluno é matriculado em apenas um ano por vez, e o ano poderá ter um ou vários alunos;
- **Aluno-Disciplina:** O aluno cursa uma ou várias disciplinas e as disciplinas podem ter um ou vários alunos.

- **Aluno-Extracurricular:** Um aluno pode cursar zero ou várias atividades extracurriculares e a atividade extracurricular poderá ser cursada por zero ou vários alunos, ou seja, a atividade poderá ser ofertada e não possuir estudantes matriculados.
- **Histórico-Extracurricular:** Um histórico poderá conter zero ou várias atividades extracurriculares e a atividade extracurricular poderá estar dentro de zero ou vários históricos, ou seja, a atividade poderá ser ofertada e não ter tido nenhum aluno que cursou.
- **Histórico-Disciplina:** Um histórico poderá ter uma ou várias disciplinas para que o histórico consiga ser gerado. A disciplina poderá existir em zero ou nenhum histórico, poderá ter sido ofertada, mas que nenhum aluno tenha cursado para constar no histórico. Considerando ainda as distinções de históricos escolares existentes entre as diferentes instituições.
- **Ano-Disciplina:** O ano poderá ter uma ou várias disciplinas e a disciplina poderá pertencer a um ou vários anos.

Figura 4: Modelo de Entidade-Relacionamento para dados do Histórico Escolar



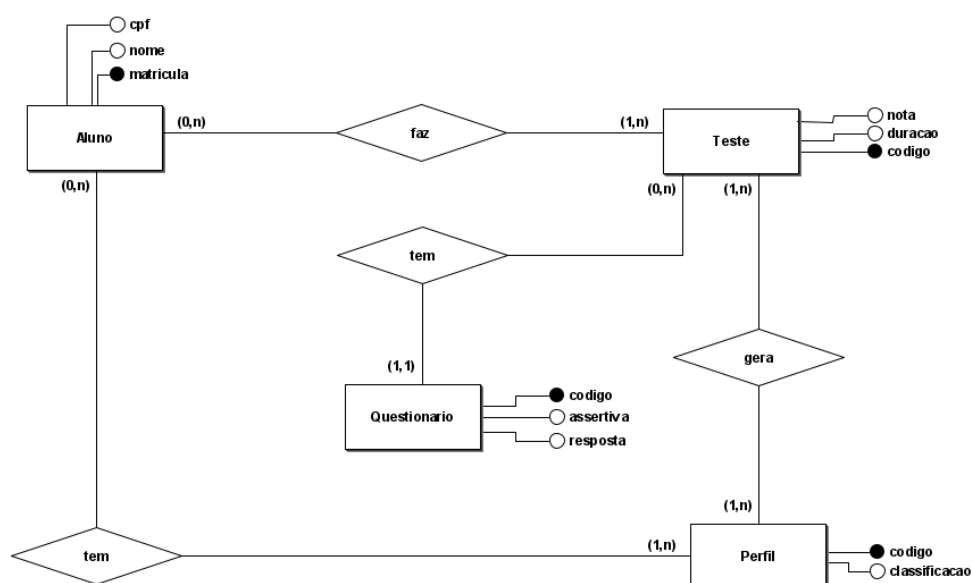
Fonte: Autora (2023)

A Figura 5 representa o modelo de dados para os dados de questionário de perfil dos estudantes. Para facilitar a compreensão, o modelo de dados foi dividido em duas partes, a

primeira parte do histórico escolar está representada na Figura 4 e a segunda parte está representada na Figura 5. Abaixo são descritos todos os relacionamentos entre as entidades de acordo com o modelo.

- **Aluno-Teste:** O aluno poderá fazer um ou vários testes e os testes poderão ser feitos por zero ou vários alunos.
- **Aluno-Perfil:** O aluno poderá ter um ou vários perfis e os perfis poderão ser tidos por zero ou vários alunos.
- **Teste-Questionário:** O teste poderá ter apenas um questionário, considerando o questionário como um conjunto de várias assertivas. O mesmo questionário poderá estar presente em um ou mais testes.
- **Teste-Perfil:** O teste poderá gerar um ou vários perfis e o mesmo perfil poderá gerar um ou mais testes.

Figura 5. Modelo de Entidade-Relacionamento para Dados do Questionário de Perfil



Fonte: Autora (2023)

4.4 Processo de Coleta de Dados

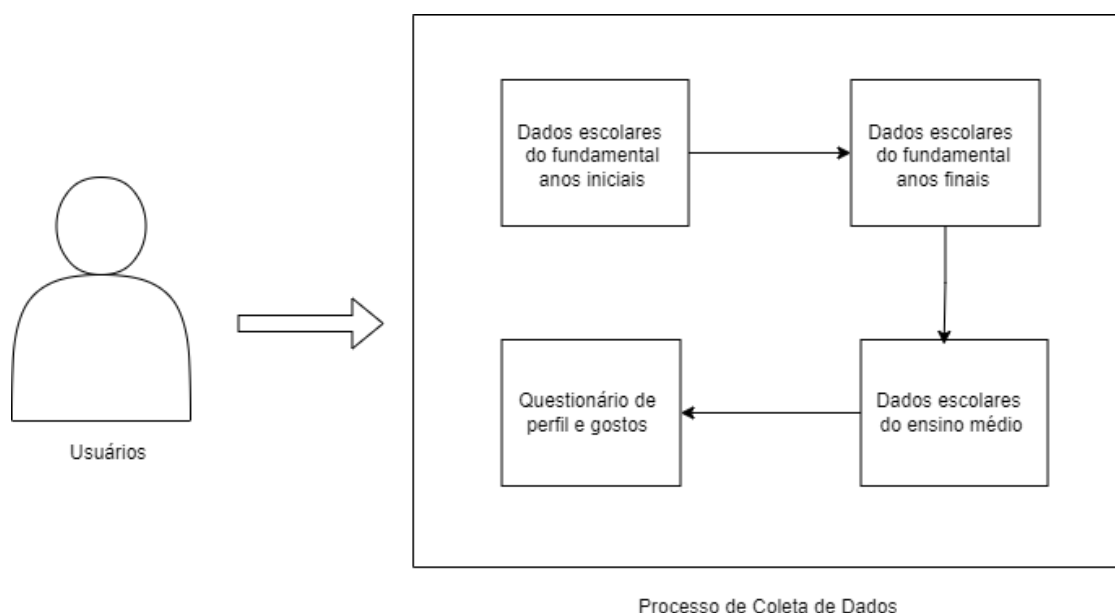
Os dados que serão coletados para o SR e o fluxo de coleta estão representados na Figura 6. A coleta de dados para o SR acontecerá inicialmente com uma entidade coletora que receberá os dados do histórico escolar do aluno do ensino fundamental anos iniciais em formato PDF, os dados serão pré-processados para geração de um segundo arquivo com os dados do histórico em formato XML para serem consumidos pelo sistema. O PDF conterá as

disciplinas cursadas, os anos e a média anual por disciplina. Esses dados serão processados e alimentará a primeira cadeia do fluxo de processamento de dados.

Após a coleta dos dados anteriores, será coletado os dados referente ao histórico escolar do ensino fundamental anos finais, também em formato PDF que será pré-processado de gerado um novo arquivo de saída em formato XML, contendo os dados de disciplinas cursadas, anos e a média anual por disciplina e atividades extracurriculares. Encerrado o pré-processamento dos dados anteriores será realizada a coleta de dados do ensino médio contendo também as disciplinas cursadas, áreas de aprendizagem, anos, a média anual por disciplinas, curso integrado e atividades extracurriculares.

Os dados coletados do histórico escolar serão processados e alimentará a primeira camada do SR. A segunda camada será composta pelos dados do questionário de gostos. O questionário será aplicado na forma de um formulário, contendo questões comuns de diversas áreas, bem como questões subjetivas que serão avaliadas por um mecanismo de processamento de texto que encontrará palavras chaves nas respostas dos alunos para processar os dados completos do questionário de gostos e alimentar a segunda camada do sistema de recomendação.

Figura 6: Modelo do Processo de Coleta de Dados

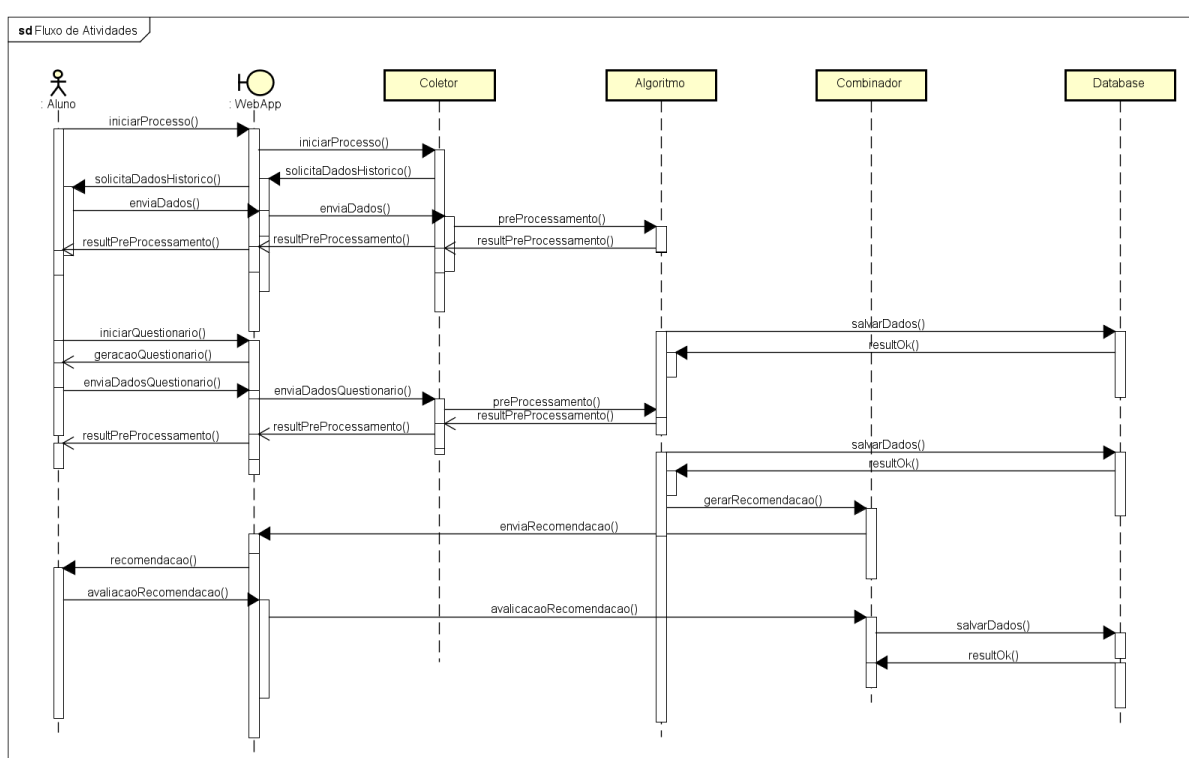


Fonte: Autora (2023).

4.5 Processo de Tomada de Decisão

O processo de tomada de decisão do modelo está sendo mostrado de forma simplificada na Figura 7. O processo de coleta de dados para fins de simplificação foi concentrado em apenas uma etapa de coleta, mas o processo completo está descrito na seção anterior. A coleta de dados compreenderá os dados do histórico do ensino fundamental anos iniciais, ensino fundamental anos finais e ensino médio. Além dos dados referentes às disciplinas e suas respectivas notas, serão coletadas todas as atividades extracurriculares realizadas pelo aluno durante o ensino básico.

Figura 7: Modelo do Processo de Tomada de Decisão



Fonte: Autora (2023)

Com a finalização do envio dos dados referente ao histórico, os dados serão pré-processados pelo algoritmo e retornados um resultado booleano para o Coletor que retornará uma mensagem personalizada para o usuário. A próxima etapa é a inicialização do questionário, onde após o processamento com sucesso dos dados anteriores será habilitado um botão de “Iniciar questionário”, onde o usuário irá clicar e o WebApp irá gerar um questionário baseado no modelo RIASEC para o aluno.

O questionário será gerado e conterá 48 assertivas, essas assertivas referem-se aos estímulos de ordem objetiva dos seres humanos, relacionados com seus dons ou talentos individuais, percepção intrínseca segundo a identificação focada em seus interesses

interpessoais (FEA, 2023). No questionário, o estudante irá avaliar entre 1 e 10, onde 1 significa **nenhuma afinidade** e 10 significa **extrema afinidade**, a figura 8 exibe uma lista de assertivas em uma escala de 1 a 10 para avaliação. Após a realização, o estudante submete o questionário e o algoritmo irá pré-processar os dados e enviará um comando para o combinador para gerar as recomendações.

Figura 8: Assertivas do Modelo RIASEC

	1	2	3	4	5	6	7	8	9	10
Trabalhos manuais com eletricidade, marcenaria, etc	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Ler pesquisas de cientistas	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Fazer coisas artesanais	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Interesses por temas psicológicos	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Elaborar estratégias empresariais	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Interesses em franquias de negócios	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Elaborar serviços contábeis	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

Fonte: FEA¹⁵ (2023)

O resultado da recomendação poderá ser um ou mais perfis, dentre os quais são elencados áreas e cursos de atuação possíveis. O Quadro 2 exibe um exemplo de uma possível saída do recomendador para a escolha de um curso técnico de nível subsequente segundo o Catálogo Nacional de Cursos Técnico¹⁶, com o eixo técnico mais correlacionado com os dados do usuário, e os respectivos cursos com maior taxa de afinidade dentre as possibilidades do eixo. Será habilitada também uma coluna com a possibilidade de avaliar cada recomendação gerada de curso gerada, com esses dados será possível com que o recomendador aperfeiçoe o construção de perfis dos estudantes, bem como as recomendações geradas.

Quadro 2 - Resultado do SR para o Ensino Tecnológico de Nível Técnico

Eixo Técnico	Cursos Correlatos	Taxa de afinidade	Avaliar
--------------	-------------------	-------------------	---------

¹⁵ <https://fce.edu.br/testevocacional/homes.php>

¹⁶ <http://cnct.mec.gov.br/>

Informação e Comunicação	Técnico em Computação Gráfica	85%	<input type="checkbox"/> Sim <input type="checkbox"/> Não
	Técnico em Desenvolvimento de Sistemas	70%	<input type="checkbox"/> Sim <input type="checkbox"/> Não
	Técnico em Informática	55%	<input type="checkbox"/> Sim <input type="checkbox"/> Não
	Técnico em Informática para Internet	50%	<input type="checkbox"/> Sim <input type="checkbox"/> Não
	Técnico em Manutenção e Suporte em Informática	40%	<input type="checkbox"/> Sim <input type="checkbox"/> Não
	Técnico em Programação de Jogos Digitais	30%	<input type="checkbox"/> Sim <input type="checkbox"/> Não
	Técnico em Redes de Computadores	5%	<input type="checkbox"/> Sim <input type="checkbox"/> Não

Fonte: Autora (2023)

O Quadro 3 exibe um exemplo de uma possível saída do recomendador para a escolha de um curso da educação superior, com as grandes áreas mais correlacionadas com os dados do usuário, e os respectivos cursos com maior taxa de afinidade dentre as possibilidades da grande área, bem como a aba de avaliação da recomendação.

Quadro 3 - Resultado do SR para o Ensino Superior

Área	Cursos Correlatos	Taxa de afinidade	Avaliar
Ciências Exatas e da Terra	Sistemas de Informação	70%	<input type="checkbox"/> Sim <input type="checkbox"/> Não
	Matemática	50%	<input type="checkbox"/> Sim <input type="checkbox"/> Não
	Probabilidade e Estatística	55%	<input type="checkbox"/> Sim <input type="checkbox"/> Não
	Ciência da Computação	85%	<input type="checkbox"/> Sim

			<input type="checkbox"/> Não
	Física	40%	<input type="checkbox"/> Sim <input type="checkbox"/> Não
	Química	30%	<input type="checkbox"/> Sim <input type="checkbox"/> Não
	Oceanografia	5%	<input type="checkbox"/> Sim <input type="checkbox"/> Não
Ciências Biológicas	Biologia	20%	<input type="checkbox"/> Sim <input type="checkbox"/> Não
	Biotecnologia	35%	<input type="checkbox"/> Sim <input type="checkbox"/> Não

Fonte: Autora (2023)

O Quadro 4 exibe um exemplo de uma possível saída do recomendador para cursos tecnológicos de nível superior segundo o Catálogo Nacional de Cursos Superiores de Tecnologia¹⁷. Com a recomendação enviada ao usuário, é solicitada ao aluno que avalie as recomendações realizadas. As avaliações são armazenadas na base de dados e servirão para treinamento futuro do modelo de recomendação.

Quadro 4 - Resultado do SR para o Eixo Tecnológico de Nível Superior

Eixo Tecnológico	Cursos Correlatos	Taxa de afinidade	Avaliar
Informação e Comunicação	Análise e Desenvolvimento de Sistemas	85%	<input type="checkbox"/> Sim <input type="checkbox"/> Não
	Banco de Dados	70%	<input type="checkbox"/> Sim <input type="checkbox"/> Não
	Redes de Computadores	55%	<input type="checkbox"/> Sim <input type="checkbox"/> Não
	Segurança da Informação	50%	<input type="checkbox"/> Sim <input type="checkbox"/> Não
	Sistemas para Internet	40%	<input type="checkbox"/> Sim <input type="checkbox"/> Não

¹⁷ <http://portal.mec.gov.br/catalogos-nacionais-de-cursos-superiores-de-tecnologia>

	Telemática	30%	<input type="checkbox"/> Sim <input type="checkbox"/> Não
	Agrocomputação	5%	<input type="checkbox"/> Sim <input type="checkbox"/> Não

Fonte: Autora (2023)

A taxa de afinidade é definida por um conjunto de métricas usadas em SR, para este trabalho serão consideradas as seguintes métricas:

- Precisão (*accuracy*): A precisão mede a proporção de recomendações corretas feitas pelo sistema em relação ao total de recomendações. Ela é frequentemente calculada como a quantidade de itens relevantes recomendados dividida pelo número total de recomendações.
- Revocação (*recall*): O recall avalia a capacidade do sistema de recuperar todos os itens relevantes para um usuário. É calculado como a quantidade de itens relevantes recomendados dividida pelo número total de itens relevantes no conjunto de dados.
- *F1-Score*: O *F1-Score* é uma métrica que combina precisão e recall em um único valor. É útil quando há um desequilíbrio entre positivos e negativos no conjunto de dados.
- Taxa de cliques (*Click-Through Rate - CTR*): Essa métrica avalia a eficácia do sistema ao medir a proporção de recomendações que resultam em cliques ou interações por parte do usuário.

5 CONCLUSÃO

O presente trabalho objetivou desenvolver um modelo de SR para o apoio a estudantes que estão saindo do ensino médio que desejam cursar um ensino técnico de nível subsequente ou nível superior. O modelo possibilita com que o aluno submeta as suas informações de todo o seu ensino básico além de responder a um questionário para identificação do perfil, onde ao final da avaliação, os dados são submetidos pelo aluno e será gerado um perfil com um conjunto de áreas ou eixos tecnológicos e os cursos relacionados ao perfil do usuário.

Avaliando o histórico escolar do aluno é possível avaliar todo o ensino básico, analisando as principais disciplinas com afinidades a partir das notas obtidas, além de observar o conjunto de atividades complementares que foram desenvolvidas ao decorrer do seu ensino básico, contemplando atividades artísticas, esportivas, musicais, tecnológicas e

empreendedorismo. Além dos dados do histórico, é gerado para o aluno um questionário baseado no modelo RIASEC para identificação das áreas com maior afinidade. A união entre o histórico escolar do aluno e seus gostos poderá auxiliar ainda mais no processo de escolha de um curso do ensino técnico ou ensino superior.

O presente trabalho trouxe a modelagem de um SR para auxiliar estudantes na escolha de curso. A recomendação gerada pelo modelo não é definitiva e deve funcionar como apoio para os estudantes, não dispensando o acompanhamento vocacional de um profissional, caso seja necessário. Com a realização da pesquisa foi possível perceber que não há na literatura um trabalho focado no desenvolvimento de um modelo de SR para apoio aos estudantes na escolha de uma área de atuação, mas há trabalhos elencando a importância do uso de SR no âmbito educacional, apoiando os estudantes durante o todo o processo no ambiente acadêmico, para isso o presente trabalho cumpre a primeira questão de pesquisa.

Ao considerar características de todo o ensino básico do aluno bem como com a aplicação de um questionário de identificação de perfil, foi possível utilizar todos os aspectos escolares do estudante, como o conjunto de notas nas disciplinas e todas as atividades extracurriculares realizadas. As informações escolares juntamente com o questionário de identificação de perfil torna o processo de recomendação mais eficaz ao considerar toda a trajetória escolar juntamente com os gostos e aspirações atuais do aluno, dessa forma, o presente trabalho cumpre a segunda questão de pesquisa.

O presente trabalho traz a modelagem de um SR e apesar de não trazer a implementação e a aplicação do modelo com estudantes, o trabalho tem sua relevância ao considerar um modelo de SR para auxílio de estudantes que estão saindo do ensino médio em busca de um curso na educação técnica de nível subsequente ou de nível superior. Sabe-se que a saída do ensino médio representa um momento importante da vida dos estudantes que precisam dar um passo para o futuro, seja escolhendo seguir na carreira acadêmica ou seja na busca por uma especialização técnica que permita a entrada mais rápida no mercado de trabalho. Dessa forma, o presente trabalho destaca sua importância como modelo de SR para apoio aos estudantes que estão no processo de escolha do próximo passo para definição do seu futuro.

6 TRABALHOS FUTUROS

Como trabalhos futuros pretende-se implementar o modelo para o desenvolvimento de uma ferramenta para aplicação com dois níveis de estudantes: (1) estão cursando o ensino médio; e (2) estudantes que acabaram o ensino médio a mais de 1 ano. O primeiro nível de estudante considera o *mindset* de um estudante ainda inserido no ambiente acadêmico, enquanto o segundo nível de estudante considerará o *mindset* de um estudante que já saiu do ambiente acadêmico e deseja-se observar as suas aspirações quanto ao prosseguindo no ambiente acadêmico ou aspirações relacionados ao mercado de trabalho.

Com a implementação da ferramenta, a aplicação poderá ser realizada de forma presencial ou de forma remota. Com os resultados da aplicação será possível determinar o nível de efetividade da solução proposta com os requisitos já considerados. Após o resultado da primeira aplicação, pretende-se testar novos algoritmos de recomendação de modo a obter a melhor performance a partir da avaliação dos alunos sobre a recomendação gerada.

REFERÊNCIAS

- ADOMAVICIUS, G.; TUZHILIN, A. Toward the Next Generation of Recommender Systems: A Survey of the State-of-the-Art and Possible Extensions. *IEEE Transactions on Knowledge and Data Engineering*, v. 17, n. 6, p. 734-749, jun. 2005. Disponível em: <<https://ieeexplore.ieee.org/document/1423975>>. Acesso em: 17 jul. 2023.
- AGGARWAL, C. An Introduction to Recommender Systems. In: AGGARWAL, C. (Ed.). *Recommender Systems: The Textbook*. Cham: Springer I. Publishing, 2016. p. 1–28.
- ALMEIDA, Maria Elizabeth Bianconcini de. Tecnologia e educação a distância: abordagens e contribuições dos ambientes digitais e interativos de aprendizagem. In: **Reunião anual da Anped**, v. 26, 2003.
- AMARAL, Geovana de Souza; RAMOS, David Brito; RAMOS, Ilmara M. M.; OLIVEIRA, Elaine H. T. de. Um Sistema de Recomendação de Estratégias de Aprendizagem Baseado no Perfil de Motivação do Aluno: SisREA. In: SIMPÓSIO BRASILEIRO DE INFORMÁTICA NA EDUCAÇÃO (SBIE), 32., 2021, Online. Anais [...]. Porto Alegre: Sociedade Brasileira de Computação, 2021. p. 718-727. DOI: <https://doi.org/10.5753/sbie.2021.218743>.
- BELVIN, N. J.; CROFT, W. B. Information Filtering and Information Retrieval: two sides of the same coin? *Communications of the ACM*, New York, v. 35, n. 12, p. 29, Dec. 1992.
- BIEDRZYCKI, T. F. (2022). A MUDANÇA DE MINDSET NO CURSO DE EDUCAÇÃO FÍSICA DO UNIVAG: OS DESAFIOS DO PROJETO TEMA INTEGRADOR. *CONNECTION LINE - REVISTA ELETRÔNICA DO UNIVAG*, (28). <https://doi.org/10.18312/connectionline.v0i28.2068>.
- BRAIDA, Filipe. Introdução a Sistemas de Recomendação | Sistemas de Recomendação. YouTube, 7 de fevereiro de 2022. Disponível em: <https://www.youtube.com/watch?v=azyHnGdkWRQ&list=PLnzT8EWpmbkAwFjY8uK7ttaBrmi1_4D&index=3>. Acesso em: 17 de julho de 2023.
- BURKE, R. Hybrid Recommender Systems: Survey and Experiments. *User Modeling and User-Adapted Interaction*, v. 12, p. 331-370, 2002. Disponível em <<http://portal.acm.org/citation.cfm?id=586352>>. Acesso: 17 jul. 2023.

CAZELLA, Sívio César et al. Recomendação de objetos de aprendizagem empregando filtragem colaborativa e competências. In: **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**, 2009.

CAZELLA, S.C.; CORRÊA, I.; REATEGUI, E. Um modelo para recomendação de conteúdos baseado em filtragem colaborativa para dispositivos móveis. *Revista Novas Tecnologias na Educação*, v. 7, p. 12-22, 2008.

CAZELLA, S.C.; NUNES, M.A.S.N.; REATEGUI, E.B. **A Ciência da Opinião: Estado da arte em Sistemas de Recomendação**. In: ANDRÉ PONCE DE LEON F. DE CARVALHO, 2010, p. 161-216. 139, 2010.

DAROS, Thuinie. **Mentalidade Criativa: Preparando Estudantes para Serem Inovadores e Resolutivos**. Grupo A Educação, 2023.

DA SILVA MONTEIRO, Jean Carlos. ASSISTENTE CHATGPT NA EDUCAÇÃO: POSSIBILIDADES E DESAFIOS. **Revista Ibero-Americana de Humanidades, Ciências e Educação**, v. 9, n. 6, p. 2899-2906, 2023.

ENGELMAN, R.; SCHREIBER, D.; BOHNENBERGER, M. C.; BESSI, V. G.. **Aprendizagem em comunidades de prática: estudo em um grupo de pesquisa**. *Contextus – Revista Contemporânea de Economia e Gestão*, v. 15, n. 2, p. 34-58, 2017. Universidade Federal do Ceará. <https://doi.org/10.19094/contextus.v15i2.908>.

FACULDADE CAMPOS ELÍSEOS. Teste Vocacional DCE. Disponível em: <<https://fce.edu.br/testevocacional/homes.php>>. Acesso em: 12 jun. 2023.

FELIX, C., FERNANDES C.. **O futuro da educação é on-line?** Discussão sobre tecnologia e educação a partir de uma visão crítica. *Perspectivas em humanidades digitais | Dossiê temático*. Acervo, Rio de Janeiro, v. 35, n. 1, jan./abr. 2022. <https://revista.an.gov.br/index.php/revistaacervo/article/view/1776/1722>.

FLORES, L. Y., SPANIERMAN, L. B., ARMSTRONG, P. I., & VELEZ, A. D. Validity of the Strong Interest Inventory and Skills Confidence Inventory With Mexican American High School Students. *Journal of Career Assessment*, v. 14, n. 2, p. 183-202, 2006. <https://doi.org/10.1177/1069072705283760>.

GOMEZ, Margarita Victoria. Paulo Freire: re-leitura para uma teoria da informática na educação. USP-NCE, São Paulo, 1999.

GERONIMO, Alisson de Villa et al. Um sistema de recomendação de conteúdo suportado pela computação distribuída. 2015.

KOSTER, Raph. **Theory of fun for game design**. " O'Reilly Media, Inc.", 2013.

LEITE, Samara Ferreira et al. **O uso das tecnologias digitais de informação e comunicação TDICS na educação básica: Desafios e vantagens**. Dissertação de Mestrado, 2021.

Lave, J. (1991). Situating learning in communities of practice. Perspectives on socially shared cognition, 2, 63-82.

Lave, J., & Wenger, E. (1998). Communities of practice: Learning, meaning, and identity.

MORAES NETO, Antônio Justiniano; FERNANDES, Marcia Aparecida; AMIEL, Tel. Chatbot e Análise Conversacional para Recomendação da Aprendizagem Colaborativa na EaD. In: SIMPÓSIO BRASILEIRO DE INFORMÁTICA NA EDUCAÇÃO (SBIE), 31., 2020, Online. Anais [...]. Porto Alegre: Sociedade Brasileira de Computação, 2020. p. 1142-1151. DOI: <https://doi.org/10.5753/cbie.sbie.2020.1142>.

OLIVEIRA, Othon & OLIVEIRA, Marcos de Souza & BANDRÃO, Orlando & SALES, Eric. (2020). Modelo preditivo para classificação de estudantes com retenção universitária. Revista dos Mestrados Profissionais, v. 5. 10.52614/2317-0115.2016.244962.

Patrick Ian Armstrong, Sarah Fetter Anthoney, Personality facets and RIASEC interests: An integrated model, Journal of Vocational Behavior, Volume 75, Issue 3, 2009, Pages 346-359, ISSN 0001-8791, <https://doi.org/10.1016/j.jvb.2009.05.004>. (<https://www.sciencedirect.com/science/article/pii/S0001879109000657>).

Peixoto, J., & Araújo, C. H. dos S.. (2012). Tecnologia e educação: algumas considerações sobre o discurso pedagógico contemporâneo. Educação & Sociedade, 33(118), 253-268. <https://doi.org/10.1590/S0101-73302012000100016>.

PIMENTEL, Mariano; FILIPPO, Denise; SANTORO, Flávia Maria. Design Science Research: fazendo pesquisas científicas rigorosas atreladas ao desenvolvimento de artefatos computacionais projetados para a educação. In: JAQUES, Patrícia Augustin; PIMENTEL,

Mariano; SIQUEIRA; Sean; BITTENCOURT, Ig. (Org.) Metodologia de Pesquisa Científica em Informática na Educação: Concepção de Pesquisa. Porto Alegre: SBC, 2020. (Série Metodologia de Pesquisa em Informática na Educação, v. 1) Disponível em: <https://metodologia.ceie-br.org/livro-1/>.

PONTES, Walber & MARTINS FRANÇA, Rômulo & COSTA, Ana & BEHAR, Patricia. (2014). Filtragens de Recomendação de Objetos de Aprendizagem: uma revisão sistemática do CBIE. p. 549. 10.5753/cbie.sbie.2014.549.

RESNICK, P. e VARIAN, H. R. (1997). Recommender Systems. Communications of the ACM, New York, v. 40, n. 3, pp. 55-58, Mar.

RODRIGUES, Pricila Resende. Uma linguagem visual para definição de strings de busca acadêmica. 2017.

SANTAELLA, Lúcia. Desafios da ubiquidade para a educação. Revista Ensino Superior Unicamp, v. 9, n. 1, p. 19-28, 2013.

SANTOS, Luanna Aretuska Silva. Vantagens e dificuldades das tecnologias de informação e comunicação na educação. **Revista Ibero-Americana de Humanidades, Ciências e Educação**, v. 8, n. 1, p. 206-217, 2022.

SANTOS, A. A. A. d., Alcara, A. R., e Zenorini, R. d. P. C. (2013). Estudos psicométricos da escala de motivação para a aprendizagem de universitários. *Fractal: Revista de Psicologia*, v. 25, p. 531–546.

SANTOS, Edméa. Educação online para além da EAD: um fenômeno da cibercultura. In: **Actas do X Congresso Internacional Galego-Português de Psicopedagogia. Braga: Universidade do Minho**. 2009. p. 5658-5671.

Schafer, J. B., Konstan, J., Riedl, J. (2001) “E-Commerce Recommendation Applications” In *Data Mining and Knowledge Discovery*, Hingham, MA, USA, Vol 5. Issue 5, Kluwer Academic Publishers.

TAVARES, Luis Antonio; MEIRA, Matheus Carvalho; DO AMARAL, Sergio Ferreira. Inteligência Artificial na Educação: Survey. **Brazilian Journal of Development**, v. 6, n. 7, p. 48699-48714, 2020.

The Big Five Personality Traits in the Political Arena. Alan S. Gerber, Gregory A. Huber, David Doherty, and Conor M. Dowling. *Annual Review of Political Science*, v. 14, n. 1, p. 265-287, 2011.

TINTO, V. Limits of Theory and Practice in Student Attrition: *The Journal of Higher Education*.Cap.53(6).p. 687–700, 1982. Disponível em: <<http://doi.org/10.2307/1981525>>. Acesso em: 17 jul. 2013.


TORI, R. TECNOLOGIA E METODOLOGIA PARA UMA EDUCAÇÃO SEM DISTÂNCIA. *EmRede - Revista de Educação a Distância, [S. l.]*, v. 2, n. 2, p. 44–55, 2016. DOI: 10.53628/emrede.v2i2.64. Disponível em: <https://www.aunirede.org.br/revista/index.php/emrede/article/view/64>. Acesso em: 15 set. 2023.

VALENTE, José Armando. A comunicação e a educação baseada no uso das tecnologias digitais de informação e comunicação. **UNIFESO-Humanas e Sociais**, v. 1, n. 01, p. 141-166, 2014.


XIAO, J., WANG, M., JIANG, B.; LI, J. A personalized recommendation system with combinational algorithm for online learning . *Journal of Ambient Intelligence and Humanized Computing*, jun. 2018, v. 9, n. 3, pp. 667–677.

ANEXOS

ANEXO A – Modelo de Histórico Escolar do Ensino Fundamental

	GOVERNO DO ESTADO DE SÃO PAULO										
	SECRETARIA DE ESTADO DA EDUCAÇÃO										
	DIRETORIA DE ENSINO REGIÃO DE										
	EE										
	Ato Legal de criação: _____										
	Endereço: _____ Nº _____										
Bairro: _____			Município: _____			Cep: _____					
Telefone: () _____ Endereço eletrônico: _____											
HISTÓRICO ESCOLAR - ENSINO FUNDAMENTAL											
Nome: _____			RG/RNE: _____			RA: _____					
Nascimento:			Município: _____			Estado: _____			País: _____		
Data: _____											
Fundamento Legal: Lei Federal 9394/96.	COMPONENTES CURRICULARES		ANO/ PERÍODO LETIVO								
			CICLO I / ANOS INICIAIS					CICLO II / ANOS FINAIS			
			ANO	ANO	ANO	ANO	ANO	ANO	ANO	ANO	
			1º Ano	2º Ano/ 1ª Bêta	3º Ano/ 2ª Bêta	4º Ano/ 3ª Bêta	5º Ano/ 4ª Bêta	6º Ano/ 5ª Bêta	7º Ano/ 6ª Bêta	8º Ano/ 7ª Bêta	9º Ano/ 8ª Bêta
	BASE NACIONAL COMUM	Língua Portuguesa									
		Arte									
		Educação Física									
		História									
		Geografia									
		Matemática									
		Ciências Físicas e Biológicas									
	Ensino Religioso										
	TOTAL DE AULAS DA BASE COMUM										
	PARTE DIVERSIFICADA	Língua Estrangeira Moderna - Inglês									
TOTAL DE AULAS DA PARTE DIVERSIFICADA											
TOTAL DE AULAS ANUAIS (Aulas)											
TOTAL DA CARGA HORÁRIA ANUAL (Horas)											
ESCOLA DE ORIGEM											
ESTUDOS REALIZADOS	Série/Ano	ANO	ESTABELECIMENTO DE ENSINO				MUNICÍPIO		UF		
	1º Ano										
	1ª série/ 2º Ano										
	2ª série/ 3º Ano										
	3ª série/ 4º Ano										
	4ª série/ 5º Ano										
	5ª série/ 6º Ano										
	6ª série/ 7º Ano										
	7ª série/ 8º Ano										
8ª série/ 9º Ano											
ESCALA DE AVALIAÇÃO: A partir de 2007 - Escala numérica de notas de 0 (zero) a 10 (dez) com patamar indicativo de desempenho escolar satisfatório, a nota igual ou superior a 05 (cinco). Os registros de avaliação das 1ª e 2ª séries do Ensino Fundamental restringir-se-ão aos componentes curriculares de Língua Portuguesa e Matemática nos termos da Resolução SE - 01, de 24/02/07. Ensino Fundamental de 9 (nove) anos, implantado a partir de 2004, de forma gradual e contínua, nos termos da Res SE 08/2008 e Deliberação CEE/SP nº 73/2008											
OBSERVAÇÕES:											
CERTIFICADO											
O Diretor da EE _____, CERTIFICA, nos termos do Inciso VII, Artigo 24 da Lei Federal 9394/96, que _____, RG _____, concluiu o Ensino Fundamental, no ano de _____.											
Número de registro da publicação - GDAE (Resolução SE108/02):											
Data: ____/____/____			Nome: _____ RG: _____ Gerente de Organização Escolar				Nome: _____ RG: _____ Diretor de Escola				

ANEXO A – Modelo de Histórico Escolar do Ensino Médio

		GOVERNO DO ESTADO DE SÃO PAULO						
		SECRETARIA DE ESTADO DA EDUCAÇÃO						
		DIRETORIA DE ENSINO REGIÃO DE						
		EE						
		Ato legal de criação:						
		Endereço:				nº		
		Bairro:		Município:		CEP:		
		Telefone:				Endereço eletrônico:		
HISTÓRICO ESCOLAR - ENSINO MÉDIO								
Nome do Aluno:		RG/RNE:			RA:			
Nascimento:		Município:		Estado:		País:		
		Data:						
Fundamento Legal: Lei Federal 9394/96	BASE NACIONAL COMUM	ÁREAS DE CONHECIMENTO		COMPONENTES CURRICULARES		Ano	Ano	Ano
						1ª Série	2ª Série	3ª Série
		Linguagens		Língua Portuguesa e Literatura				
				Arte				
				Educação Física				
		Matemática		Matemática				
		Ciência da Natureza		Biologia				
				Física				
				Química				
		Ciências Humanas		História				
			Geografia					
			Filosofia					
			Sociologia					
			Total de Aulas da Base Nacional Comum					
	PARTE DIVERSIFICADA	Língua Estrangeira Moderna		Inglês				
		Espanhol						
		Total de Aulas da Parte Diversificada						
		Total de Aulas Anual do Curso (Aulas)						
		Total de Carga Horária Anual do Curso (Horas)						
Ensino Fundamental		Série	Ano	Estabelecimento de Ensino		Município	UF	
		8ª Série/ 9º Ano						
Ensino Médio		1ª Série						
		2ª Série						
		3ª Série						
Escala de Avaliação: "A partir de 2007 - Escala numérica de notas de 0 (zero) a 10 (dez) com patamar indicativo de desempenho escolar satisfatório, a nota igual ou superior a 05 (cinco) nos termos da Resolução SE - 61, de 24/9/2007."								
OBSERVAÇÕES:								
CERTIFICADO								
O Diretor da EE _____, RG _____, CERTIFICA, nos termos do Inciso VII, Artigo 24 da Lei Federal 9394/96, que _____, RG _____, concluiu o Ensino Médio, no ano de _____.								
Número de registro da publicação - GDAE (Resolução SE108/02):								
Data: ____/____/____				Nome: RG: Gerente de Organização Escolar		Nome: RG: Diretor de Escola		

Fonte: Governo do Estado de São Paulo, 2023.