

Fernanda Fernandes Peronaglio

Adaptação automática de conteúdo
aplicada em ambiente interativo com
aprendizagem individualizada

São José do Rio Preto
2024

Fernanda Fernandes Peronaglio

Adaptação automática de conteúdo
aplicada em ambiente interativo com
aprendizagem individualizada

Tese apresentada como parte dos requisitos para obtenção do título de Doutor em Ciência da Computação, junto ao Programa de Pós-Graduação em Ciência da Computação (PPGCC), do Instituto de Biociências, Letras e Ciências Exatas da Universidade Estadual Paulista “Júlio de Mesquita Filho”, Câmpus de São José do Rio Preto.

Orientador:

Prof. Dr. Aleardo Manacero Jr.

Coorientador:

Prof. Dr. Alexandro J. Baldassin

**São José do Rio Preto
2024**

P453a

Peronaglio, Fernanda Fernandes

Adaptação automática de conteúdo aplicada em ambiente interativo com aprendizagem individualizada / Fernanda Fernandes Peronaglio. -- São José do Rio Preto, 2024

104 f. : il., tabs.

Tese (doutorado) - Universidade Estadual Paulista (UNESP), Instituto de Biociências Letras e Ciências Exatas, São José do Rio Preto

Orientador: Aleardo Manacero

Coorientador: Alexandro José Baldassin

1. Ciência da computação. 2. Sistemas tutoriais inteligentes. 3. Processamento de linguagem natural. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Universidade Estadual Paulista (UNESP), Instituto de Biociências Letras e Ciências Exatas, São José do Rio Preto. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.

Fernanda Fernandes Peronaglio

Adaptação automática de conteúdo aplicada em ambiente interativo com aprendizagem individualizada

Tese apresentada como parte dos requisitos para obtenção do título de Doutor em Ciência da Computação, junto ao Programa de Pós-Graduação em Ciência da Computação (PPGCC), do Instituto de Biociências, Letras e Ciências Exatas da Universidade Estadual Paulista “Júlio de Mesquita Filho”, Câmpus de São José do Rio Preto.

Comissão Examinadora:

Prof. Dr. Aleardo Manacero Jr.
UNESP - Câmpus de São José do Rio Preto
Orientador

Prof. Dr. Rodrigo Capobianco Guido
UNESP - São José do Rio Preto

Prof. Dr. Arnaldo Candido Junior
UNESP - São José do Rio Preto

Prof. Dr. Anderson Soares
UFG - Câmpus de Goiânia

Prof. Dr. Renata de Matos Galante
Universidade Federal do Rio Grande do Sul

São José do Rio Preto
07 de agosto de 2024

Aos meus pais José Carlos e Rosa

À minha irmã Flávia

Agradecimentos

Agradeço primeiramente a Deus por me guiar durante toda a caminhada, permitindo-me alcançar mais esta realização e tornando possível esta conquista.

Agradeço aos meus pais, José Carlos e Rosa, por serem sempre minha base de vida, fornecendo-me apoio e suporte durante todos os meus dias. A minha irmã, Flávia, por tornar minha vida mais divertida, trazendo companheirismo e leveza a todos os momentos.

Ao meu orientador, Prof. Dr. Aleardo Manacero Jr., pela amizade e por todos os ensinamentos e direcionamentos que tornaram possível a concretização deste projeto e incrementaram meu crescimento como profissional. Agradeço por toda a confiança no meu trabalho.

Agradeço também ao Prof. Dr. Alexandro Baldassin, pela coorientação deste trabalho, por todo o suporte e apoio recebido para que fosse possível chegar até aqui.

À Prof. Dra. Renata Spolon Lobato, pela amizade e apoio durante todo este período.

Agradeço aos professores do programa por toda a dedicação, aos funcionários do Ibilce por toda ajuda e à Unesp por todo o suporte fornecido.

Resumo

Sistemas tutores inteligentes têm se destacado como ferramenta de apoio ao ensino, principalmente pela sua adaptação às condições do usuário e cenário de aplicação. Esta adaptabilidade é possível pela utilização de inteligência artificial. Além disso, a tarefa de ensino é melhor conduzida aplicando-se técnicas como aprendizagem de máquina, processamento de linguagem natural e mineração de dados para adequar o sistema a partir de informações coletadas do usuário em sua utilização.

Apesar disso, essas técnicas ainda não são fortemente exploradas para geração de conteúdo em sistemas tutores. A maioria das aplicações envolve o controle das informações e a orientação dos estudos de seus usuários por meio de recomendação de conteúdo existente. A produção de conteúdo personalizado surge, nesse cenário, como alternativa ao processo de simples recomendação, permitindo que conteúdos apresentem diferentes formatos segundo a personalidade de cada usuário.

Este trabalho desenvolveu uma metodologia de adaptação de conteúdo para ensino, aplicando técnicas de processamento de texto. O processo de produção de conteúdo personalizado permitiu um avanço na forma de uso de sistemas tutores no ensino quanto a geração de conteúdo. Como resultado foi obtido um modelo, com ferramenta aplicada ao contexto, para adaptação automática de conteúdo construído com base em estilos de aprendizagem.

Palavras-chave: Sistemas Tutores Inteligentes, Geração de Conteúdo, Geração de texto, Inteligência Artificial

Abstract

Intelligent tutoring systems have stood out as a teaching support tool, mainly due to their ability to adapt to user conditions and application scenarios. This adaptability is possible through the use of artificial intelligence. Furthermore, the creation and adaptation of materials for the system is best conducted by applying techniques such as machine learning, natural language processing and data mining.

Despite this, these techniques are not yet heavily explored for generating content in tutoring systems. Most applications involve controlling information and guiding their users' studies by recommending existing content. The production of personalized content appears, in this scenario, as an alternative to the simple recommendation process, allowing content to present different formats according to the personality of each user.

This work developed a methodology for adapting teaching content, applying natural language processing techniques. The process of producing personalized content allowed an advance in the way tutoring systems are used in teaching regarding content generation. As a result, a model was obtained, with a tool applied to the context, for automatic adaptation of content based on learning styles.

KeyWords: Intelligent Tutoring Systems, Content Generation, Text Generation, Artificial Intelligence

Lista de Figuras

Figura 1 —	Tipos de Inteligência	20
Figura 2 —	Ilustração da Taxonomia de Bloom	25
Figura 3 —	Ciclo de aprendizagem e estilos de Kolb	27
Figura 4 —	Modelo VARK	33
Figura 5 —	Modelo de grafo MDP	53
Figura 6 —	Modelo de entrada de texto	55
Figura 7 —	Modelo de texto avaliado para a questão	55
Figura 8 —	Visualização da Proposta	58
Figura 9 —	Caso de uso do modelo	62
Figura 10 —	Ciclo de Estágios	64
Figura 11 —	Resultados obtidos para categorização dos participantes em estilos	74
Figura 12 —	Resultados obtidos para afirmação sobre a capacidade do modelo de resumir pontos chave e temas centrais do texto principal	77
Figura 13 —	Ilustração do gráfico idealizado por Kolb	92

Lista de Tabelas

Tabela 1 —	Primeira versão de termos chave para tutores inteligentes .	42
Tabela 2 —	Resultados na primeira versão de termos chave para tuto- res inteligentes	42
Tabela 3 —	Versão final de termos chave para tutores inteligentes . . .	42
Tabela 4 —	Resultados na versão final de String para tutores inteligentes	42
Tabela 5 —	Trabalhos selecionados no cenário de tutores inteligentes .	43
Tabela 6 —	Avaliação quanto ao conteúdo que será utilizado no teste .	74
Tabela 7 —	Avaliação de sentimento em relação ao modelo recebido . .	75
Tabela 8 —	Avaliação da experiência em relação ao modelo recebido .	76
Tabela 9 —	Questionário do Modelo de Kolb	90

Lista de Abreviaturas e Siglas

API	Application Programming Interface
CA	Conceitualização Abstrata Concreta
CBR	Case-Based Reasoning
EA	Experimentação Ativa
EC	Experiência Concreta
GPT	Generative Pre-Training Transformer
HTML	HyperText Markup Language
IDF	Inverse Document Frequency
ITS	Intelligent Tutoring Systems
LIME	Learning, Iteration, Mentoring and Evaluation
LSQ	Learning Style Questionnaire
MDP	Markov Decision Process
NLP	Natural Language Processing
OR	Observação Reflexiva
SQL	Structured Query Language
URL	Uniform Resource Locator
VAK	Visual, Auditory and Kinesthetic
VARK	Visual, Aural, Read/Write and Kinesthetic

Sumário

1	Introdução	12
1.1	Fundamentação	13
1.2	Objetivos	14
1.3	Organização do texto	15
2	Aprendizagem - Teoria e Estilos	16
2.1	Teorias do ensino e aprendizagem	16
2.1.1	Fundamentos da psicologia	17
2.1.2	Desenvolvimento da inteligência	18
2.1.3	Teoria das inteligências múltiplas	19
2.1.4	Preferencias individuais	21
2.1.5	Teoria da instrução	23
2.1.6	Taxonomia dos objetivos educacionais	24
2.2	Modelos de aprendizagem propostos	26
2.2.1	Inventário de estilos de aprendizagem de Kolb	27
2.2.2	Modelo Honey e Mumford - LSQ	30
2.2.3	Modelo VAK/VARK	32
2.2.4	Modelo de Felder e Silverman	33
2.3	Críticas ao ensino baseado em estilos	35
2.4	Contexto de aplicação ao projeto	36
2.4.1	Provendo a adaptação de conteúdo	37
2.5	Considerações finais	37
3	Tratamento do conteúdo em sistemas tutores inteligentes	38
3.1	Revisão sistemática	38
3.1.1	Estudo complementar de outras revisões desenvolvidas na área	39
3.1.2	Estratégia de busca	40
3.1.3	Critérios de seleção	42
3.2	Extração de dados	43
3.3	Resultados obtidos - Sistemas tutores inteligentes e técnicas para produção de conteúdo	44
3.3.1	Sistemas de recomendação	44
3.3.2	Geração de questões	50
3.3.3	Avaliação do levantamento	51
3.4	Considerações Finais	56
4	Métodos e Técnicas	57
4.1	Discussão da proposta	57
4.1.1	Definição do projeto	57

4.1.2	Metodologia de desenvolvimento	59
4.1.3	Proposta da metodologia de adaptação de conteúdo	60
4.2	Definições para tratamento dos estilos de aprendizagem	61
4.2.1	Definição do modelo de aprendizagem	62
4.2.2	Versão escolhida do modelo de Kolb	63
4.2.3	Modelo Assimilador	63
4.2.4	Modelo Convergente	64
4.2.5	Modelo Acomodador	65
4.2.6	Modelo Divergente	65
4.2.7	Síntese dos métodos e formas de tratamento	66
4.3	Desenvolvimento e implementação da Proposta	68
4.3.1	Aspectos técnicos	68
4.3.2	Processamento de texto e adaptação de conteúdo	69
4.4	Considerações finais	69
5	Resultados	70
5.1	Sumarização de texto	70
5.2	Métodos extrativos	72
5.3	Métodos generativos	73
5.4	Testes de observação	73
5.5	Discussão sobre redes generativas no cenário dos resultados	77
5.6	Considerações finais	79
6	Conclusões	80
6.1	Trabalhos futuros	81
6.2	Publicações do trabalho	82
6.3	Ética em pesquisa	83
	Referências	84
	Apêndice A - Inventário de estilos de aprendizagem de Kolb	90
	Apêndice B - Materiais aplicados para os testes de observação	93
	Apêndice C - Avaliação da Pesquisa - Formulário	104

Capítulo 1

Introdução

Sistemas tutores são ferramentas importantes no contexto de ensino, principalmente no ensino à distância, oferecendo suporte à aprendizagem e complementação do conteúdo educacional. Considerando sua aplicação no cenário educacional, este trabalho propõe um aprimoramento na capacidade desses tutores, visando aumentar sua adaptabilidade para tipos de aprendizagem.

Com o avanço das técnicas de inteligência artificial, os sistemas tutores inteligentes têm sido cada vez mais aplicados, tornando-se mais específicos em suas funções de suporte ao ensino. Essa especificidade, no entanto, traz desafios significativos, relacionados tanto à diversidade de dados que esses sistemas precisam manipular quanto ao nível de aprendizagem que se espera que eles proporcionem. Em consequência, um número crescente de pesquisas tem se dedicado ao desenvolvimento e aprimoramento dessas aplicações.

Nesses sistemas cabe ao professor/instrutor inserir conteúdos no sistema tutor. Tais conteúdos tipicamente são extraídos de livros-texto ou de bases de dados consagradas. Embora esta tarefa não seja tão complexa, seu problema é criar uma restrição à diversidade de abordagens ao conteúdo que diferentes estudantes poderiam receber. Criar tal diversidade apresenta um problema de escalabilidade, uma vez que o professor teria que gerar versões manualmente (STERNBERG, 1994).

Considerando que a oferta de abordagens distintas é um requisito para que o ensino baseado em estilos de aprendizagem seja habilitado. Considerando ainda a existência de uma corrente psicopedagógica que defende que ao se ensinar algo usando a forma em que o estudante prefere aprender, os resultados obtidos são superiores ao ensino tradicional (exceto se o ensino tradicional for a forma preferida). Fica claro que é interessante que se possa criar conteúdos adequados a cada estilo de forma automática (STERNBERG, 1994).

A automação do processo de geração de conteúdos adaptados, que é o objetivo deste trabalho, pode ser feita aplicando-se nele técnicas de processamento de lingua-

gem natural. Para tanto é necessário definir qual modelo de estilos de aprendizagem será aplicado e, a partir disso, definir regras para a geração das várias versões de conteúdo, aqui limitados a textos. Desta forma, é possível disponibilizar diferentes versões de conteúdo direcionadas para os estilos de aprendizagem definidos, os quais seriam automaticamente inseridos em um tutor inteligente.

O uso de ferramentas computacionais no ensino é uma prática consolidada há muitos anos. No entanto, os sistemas tutores inteligentes se destacam pelo emprego de inteligência artificial, o que lhes permite realizar inferências sobre os dados manipulados e exercer um controle mais preciso sobre o domínio de aplicação dessas ferramentas (VANLEHN, 2011).

Para compreender o contexto de aplicação deste trabalho, é possível citar a pesquisa de Corbett, Koedinger e Anderson (CORBETT; KOEDINGER; ANDERSON, 1997), que define a arquitetura de um sistema tutor como sendo:

- Ambiente de resolução do problema - ambiente de entrada/saída de informações, sendo a interface de interação em que o usuário;
- Modelo de estudante/usuário - Características de performance e dados de utilização do usuário;
- Domínio de conhecimento - módulo principal do sistema, que realiza inferência sobre o conteúdo para tratar o contexto abordado e fornece base para compreensão de perfil do usuário;
- Módulo pedagógico - parte responsável por sequenciar a apresentação das atividades.

Neste trabalho o foco esteve diretamente nas funções do “Domínio do conhecimento”, área central da arquitetura dos sistemas tutores e que é a responsável direta pela produção e manipulação de informações.

1.1 Fundamentação

É possível encontrar diversos sistemas tutores inteligentes propostos na literatura. Como será mostrado nos próximos capítulos, as propostas possuem capacidades e propósitos variados de execução. Porém, como será abordado nas próximas seções, a maioria apresenta dificuldades relacionadas a geração de conteúdo para ser utilizado nas ferramentas.

O conteúdo de um tutor é o cerne para o alcance de seus objetivos educacionais, devendo ser apresentado de forma a melhorar a compreensão por parte dos usuários. No entanto, a geração automatizada dessas informações é um desafio significativo.

Durante a revisão da literatura, foi observado que a maioria dos sistemas tutores se limita a recomendar conteúdos já existentes, sem realizar a criação/adaptação automática de novas informações que possam ser integradas e disponibilizadas ao usuário. Isso evidencia uma limitação nos sistemas atuais, que ainda não conseguem produzir novos conteúdos adaptativos de forma autônoma.

No cenário atual, novos conteúdos ou são adicionadas por tutores humanos ou extraídas de bases de dados já existentes e analisadas. Isso limita a escalabilidade das soluções e representa um problema a ser resolvido na área.

Esse problema tem sido, em parte, atacado com técnicas de adaptação do conteúdo às características do usuário. Essas técnicas permitiram uma melhora na capacidade das ferramentas, mas, ainda assim, estes modelos trabalham com um grupo já definido de informações, sem capacidade de geração.

Com isto, fica claro que a geração automatizada de texto, adaptado a preferências individuais de cada aprendiz, é importante para o desenvolvimento de tutores inteligentes mais flexíveis e eficientes. Neste trabalho, esse problema é tratado com a aplicação de técnicas de processamento de linguagem natural, como um meio de se obter produção de conteúdo para a aplicação no ensino, atendendo ao problema existente nos sistemas tutores.

1.2 Objetivos

O objetivo central deste trabalho é propor uma metodologia que utiliza técnicas de inteligência artificial, neste cenário processamento de linguagem natural, para adaptar o conteúdo original e gerar textos direcionados às características específicas dos alunos, com base em estilos de aprendizagem previamente definidos.

A metodologia utiliza a teoria dos estilos aprendizagem e as técnicas de processamentos de texto que, a partir de um texto inicial, identificam os meios para produzir um novo texto adaptado automaticamente. Esse texto resultante mantém a essência do conteúdo original, mas é modificado para atender diferentes preferências pessoais, alinhando-se aos estilos de aprendizado.

O diferencial dessa proposta reside na geração de variantes do texto de entrada, adaptando-o de várias formas e, principalmente, produzindo novas versões sem intervenção humana. Essa abordagem traz uma inovação significativa para a área de sistemas tutores inteligentes, ao automatizar o tratamento do conteúdo educacional, permitindo personalização em larga escala.

As versões variantes são geradas a partir do texto original, considerando os estilos de aprendizagem para direcionar sua aplicação. Dessa forma, é possível criar novas apresentações de conteúdo com capacidade educativa, adaptadas às técnicas e estilos

de aprendizagem estudados, para serem aplicadas em sistemas tutores inteligentes e como suporte ao ensino.

A proposta explora a geração de conteúdo sem interferência humana, o que expande a capacidade das ferramentas educacionais ao eliminar a necessidade de inserção manual ou reescrita de novos conteúdos. Essa abordagem amplia o alcance e a eficiência dos tutores inteligentes, permitindo uma personalização automatizada que se adapta às necessidades individuais dos alunos, sem demandar intervenção contínua dos educadores.

A variante proposta é produzida em um formato mais reduzido e centrado nos tópicos principais do texto original, para que a abordagem seja mais simples ao aprendizado, destacando-se os pontos chave de estudo.

Para este trabalho, foi selecionado o modelo de estilos de aprendizagem de Kolb (KOLB, 1976a) para atuar como o direcionador da adaptação personalizada por preferências. Este modelo de aprendizagem traz a sua abordagem de ensino cíclico com compartilhamento de características entre os estilos, e permite a adequada aplicação nesta pesquisa. Além disso, o inventário é diversamente aplicado na literatura, em diferentes áreas.

1.3 Organização do texto

Este texto está organizado em seis capítulos, sendo este o primeiro deles. O Capítulo 2 trás uma fundamentação teórica do tema, necessária para compreensão do cenário, e no Capítulo 3 é abordada uma fundamentação no contexto atual de sistemas tutores.

Já no Capítulo 4, se aborda a metodologia do projeto, as técnicas escolhidas e suas características, e no Capítulo 5 se exhibe os resultados obtidos na investigação.

Por fim, o Capítulo 6 traz as conclusões sobre o trabalho, as estratégias de trabalhos futuros e as informações sobre publicações.

Capítulo 2

Aprendizagem - Teoria e Estilos

A ideia de geração automatizada de conteúdo adaptado está fundamentada no conceito de estilos de aprendizagem. Assim, neste capítulo são apresentados estilos de aprendizagem e suas características, permitindo a compreensão do trabalho desenvolvido.

2.1 Teorias do ensino e aprendizagem

A variabilidade do comportamento humano e a capacidade de executar atividades de maneiras diferentes, influenciaram o interesse no ramo da pesquisa sobre aprendizagem. As pesquisas sobre os estilos de aprendizagem buscam entender como os seres humanos conseguem aprender de maneiras diferentes e são capazes de se adaptar.

Aprendizagem, apesar de inserida em um contexto geral, é um conceito trabalhado com diversas concepções ao longo dos anos, em diversas linhas de pesquisa. Entre as teorias, existem as linhas que abordam a aprendizagem e sua relação com o contexto externo, aspecto interno e interação com o meio (NUNES; SILVEIRA, 2015).

O trabalho desenvolvido por Pinto (PINTO, 1990) fornece uma boa discussão sobre a visão de aprendizagem partindo da visão da psicologia e educadores. Primeiramente, são abordadas três formas de entender o processo de aprendizagem no senso comum, sendo:

- A primeira forma defende a visão do aprendizado como um processo de imitação, em que o indivíduo presta atenção ao outro e absorve os valores;
- Já a segunda entende a aprendizagem como um processo cumulativo de conhecimento, que são adquiridos a cada aprendizado;
- Por fim, a terceira ideia entende o conhecimento como coisas, objetos, que podem ser adquiridos, acumulados e substituídos.

As três ideias abordadas anteriormente são fundadas na observação apenas do resultado da aprendizagem, o comportamento. Ou seja, a observação apenas dos comportamentos podem construir essas ideias no senso comum.

No entanto, Pinto trouxe em seu trabalho a necessidade de observar os processos mentais do aprendiz, e não apenas entendê-lo como os resultados. Imitar, repetir, são processos comportamentais e não de aprendizagem, este necessita de operações mentais para acontecer.

Para isso, o trabalho de Pinto apresentou a forma de aprendizagem como um processo dividido em fases, mostrando os objetivos e prioridades de cada etapa. Oito etapas foram apresentadas pelo autor em seu projeto, sendo:

1. Fase da Motivação: expectativa relacionada ao processo;
2. Fase da Apreensão: atenção e percepção seletiva;
3. Fase da Aquisição: codificação e formatação do conteúdo;
4. Fase de Retenção: assegurar o processo de recuperação da informação;
5. Fase da Recuperação: significação e interligação com outras informações;
6. Fase da Generalização: aplicação do conteúdo;
7. Fase de Performance: resposta ao aprendiz;
8. Fase de FeedBack: processo de reforço.

Com as observações do trabalho é possível verificar as compreensões e abordagens do processo de aprendizagem como um processo de etapas, que pode ser estudado e definido de acordo com preferências particulares.

2.1.1 Fundamentos da psicologia

As teorias da psicologia sobre o comportamento humano no aprendiz formam a base para a proposição e o estudos dos diferentes estilos de aprendizagem.

Neste cenário, pode ser citado o trabalho desenvolvido por Carl Jung (JUNG, 1954), a respeito das Teorias da Personalidade. O autor dedicou seu estudo a individualização das características do ser, e principalmente ao papel de pais e tutores no desenvolvimento da personalidade de crianças.

A teoria defendida por Jung abordava sobre o processo educacional consciente da personalidade variada do receptor, em que professores deveriam influenciar durante a estratégia de ensino o desenvolvimento das personalidades.

Também neste contexto, trabalhos na área de pesquisa da psicologia cognitiva, como os de Sternberg e Grigorenko (STERNBERG; GRIGORENKO, 1997),

começaram a avaliar os tipos de estilos cognitivos e as diferentes capacidades de assimilação do ser humano. A psicologia cognitiva começou a ser tratada como ferramenta de observação e predição de desempenho a partir dos conjuntos de características individuais apresentadas, o que reforça a teoria dos estilos de aprendizagem e a sua proposição.

Nesta linha, também é possível citar o trabalho desenvolvido por Joyce e Hodges (JOYCE; HODGES, 1966). Os autores defendem a importância da adaptabilidade do professor para o ensino em estilos diferentes, propondo em sua pesquisa o “Treinamento de flexibilidade instrucional”, que aborda a metodologia de habilidade de ensino do professor e sua influência na aprendizagem.

O trabalho de Joyce e Hodges, e o método, são fundamentados nas teorias da psicologia que defendem que a capacidade de aprender é variável entre os estudantes, e que a habilidade de ensino do professor precisa corresponder a essa realidade e ser adaptável para obter maior sucesso.

2.1.2 Desenvolvimento da inteligência

Para compreender o conceito de como a inteligência e a capacidade cognitiva é formada, o trabalho desenvolvido por Piaget a partir de 1952 é uma referência no assunto (PIAGET; COOK et al., 1952) (PIAGET, 2013). O psicólogo apresentou suas ideias sobre a origem da inteligência nas crianças, e propôs que a inteligência se desenvolve por meio de uma série de estágios sequenciais e universais que as crianças passam à medida que crescem. Esses estágios refletem mudanças qualitativas no pensamento e na compreensão do mundo.

No primeiro estágio, o sensorimotor (do nascimento até aproximadamente 2 anos), Piaget argumenta que a inteligência da criança é demonstrada por meio da ação e da interação direta com o ambiente. Durante este estágio, as crianças aprendem sobre o mundo usando seus sentidos e ações motoras. Elas começam a desenvolver a permanência do objeto, a compreensão de que os objetos continuam a existir mesmo quando não estão visíveis, e aprendem a coordenar suas atividades motoras com percepções sensoriais.

O segundo estágio é o pré-operacional (de 2 a 7 anos), em que se começa a usar símbolos para representar objetos e eventos. Durante este período, o pensamento simbólico surge, permitindo o desenvolvimento da linguagem e da imaginação. No entanto, elas ainda não conseguem realizar operações mentais lógicas, como a conservação, que é a compreensão de que a quantidade de uma substância não muda apenas porque sua forma muda.

O terceiro estágio é o operacional concreto (de 7 a 11 anos), quando a criança começa a pensar logicamente sobre eventos concretos. Durante este estágio, as

crianças desenvolvem a capacidade de realizar operações mentais sobre objetos físicos e podem entender conceitos como conservação, reversibilidade e classificação. No entanto, seu pensamento é ainda limitado a objetos concretos e experiências diretas.

O último estágio é o operacional formal (a partir de 11 anos até a idade adulta), em que o pensamento abstrato e hipotético se torna possível. Durante este estágio, os adolescentes desenvolvem a capacidade de pensar logicamente sobre conceitos abstratos, testar hipóteses de maneira sistemática e considerar possíveis alternativas ao resolver problemas. Eles também podem pensar sobre questões morais, filosóficas, éticas e sobre o futuro de forma mais sofisticada.

Piaget enfatizou que esses estágios não são apenas uma sequência de habilidades que as crianças adquirem, mas representam uma transformação fundamental na forma como elas entendem e interagem com o mundo. A teoria de Piaget destaca a importância da interação ativa com o ambiente e a construção do conhecimento por meio da experiência direta. Ele acreditava que a inteligência se desenvolve com processos de assimilação e acomodação, em que as crianças continuamente adaptam suas estruturas cognitivas em resposta a novas informações e experiências.

A teoria teve impacto profundo na psicologia do desenvolvimento e na educação, mudando a forma como entendemos o crescimento cognitivo das crianças. As ideias de Piaget continuam a influenciar práticas educacionais e pesquisas sobre desenvolvimento infantil, enfatizando a importância de um ambiente de aprendizagem que estimule a exploração e a descoberta ativa.

Também estão ligados a esta linha de pesquisa, os trabalhos na área de psicologia que alinham o desenvolvimento da inteligência com o desenvolvimento da afetividade, buscando envolver as emoções como parte do processo de evolução da inteligência na interação com o contexto (SOUZA, 2011).

2.1.3 Teoria das inteligências múltiplas

A teoria das inteligências múltiplas foi proposta por Howard Gardner (GARDNER, 1983), desafiando a visão tradicional de que a inteligência é uma capacidade única e geral. O autor sugeriu que a inteligência é multifacetada e composta por diferentes tipos, cada uma refletindo uma maneira distinta de interagir com o mundo. Ele inicialmente identificou sete tipos de inteligência, expandindo mais tarde para um total de oito, e possivelmente nove, tipos de inteligência, como vistos na Figura 1.

A inteligência linguística refere-se à capacidade de usar palavras de maneira eficaz, seja oralmente ou por escrito. Esta inteligência é característica de escritores, poetas, advogados e oradores, que demonstram habilidade em manipular a linguagem para expressar ideias e alcançar objetivos.

A inteligência lógico-matemática envolve a habilidade de raciocinar logicamente

Figura 1: Tipos de Inteligência



Fonte: (SOUZA, 2015)

e resolver problemas matemáticos. É a inteligência predominante em cientistas, matemáticos e engenheiros, que utilizam o raciocínio dedutivo e indutivo, além de habilidades analíticas para compreender padrões e resolver problemas complexos.

A inteligência espacial é a capacidade de pensar em termos de espaço físico e visualizar com precisão. Essa inteligência é frequentemente encontrada em arquitetos, artistas e pilotos, que precisam entender e manipular espaços, formas e relações espaciais de maneira eficaz.

A inteligência corporal-cinestésica diz respeito ao uso do próprio corpo para resolver problemas ou criar produtos. Atletas, dançarinos e cirurgiões são exemplos de pessoas que possuem essa inteligência desenvolvida, utilizando coordenação, equilíbrio, destreza e habilidade motora para executar tarefas específicas.

A inteligência musical envolve a habilidade de perceber, discriminar, transformar e expressar formas musicais. Músicos, compositores e maestros exemplificam essa inteligência, demonstrando sensibilidade para ritmo, melodia, timbre e harmonia.

A inteligência interpessoal é a capacidade de entender e interagir eficazmente com os outros. Pessoas com alta inteligência interpessoal, como professores, líderes e terapeutas, são hábeis em reconhecer e responder aos sentimentos, motivações e

desejos dos outros.

A inteligência intrapessoal refere-se à capacidade de entender a si mesmo, acessar emoções próprias e utilizar esse entendimento para regular a própria vida. Pessoas com alta inteligência intrapessoal, como filósofos e psicólogos, têm um profundo conhecimento de suas próprias emoções, motivações e objetivos.

Posteriormente, Gardner acrescentou a inteligência naturalista, que é a capacidade de reconhecer, categorizar e utilizar elementos do ambiente natural. Essa inteligência é comum em biólogos, ecologistas e agricultores, que demonstram uma sensibilidade especial para flora, fauna e outros elementos naturais.

Gardner também considerou a inteligência existencial, que envolve a capacidade de ponderar questões profundas sobre a existência humana, como o significado da vida e a morte. Embora não formalmente adicionada à lista original, Gardner sugeriu que essa poderia ser outra forma de inteligência que mereceria reconhecimento.

A teoria das inteligências múltiplas de Gardner foi importante para a educação ao reconhecer que os indivíduos aprendem e demonstram sua inteligência de várias maneiras. Essa visão mais ampla da inteligência permite que educadores adaptem suas abordagens pedagógicas para atender às diversas habilidades e necessidades dos alunos, promovendo um ambiente de aprendizagem mais inclusivo e eficaz.

Na linha de pesquisa em habilidades humanas, também é possível citar o trabalho de Messick (1992) (MESSICK, 1992), que avaliou a teoria de Gardner no contexto da teoria de inteligência triárquica (STERNBERG, 1985), reforçando o contexto de múltiplas formas de entender a inteligência em cada ser humano.

2.1.4 Preferencias individuais

Os estilos de aprendizagem têm como base as características e preferencias individuais para aprendizagem, sendo que muitas pesquisas foram desenvolvidas observando a apropriação de sentidos e comportamentos, como podem ser citados os estilos:

- **Visual** – Estilo com preferência por representações visuais, adeptos a utilização de imagens, esquemas, gráficos e outras visualizações (SPANELLA, 2013). Para os estudantes com essa característica as estratégias de ensino sugerem utilização de recursos visuais nas aulas para ilustrar pontos-chave e conceitos complexos. Isto inclui ferramentas como apresentações de slides com elementos visuais atraentes e informativos.

Incentivo a criação de mapas mentais e organizadores gráficos para estruturar informações e conceitos, promovendo o uso de anotações visuais para ajudar os alunos a organizar e reter informações.

Além disso, também é possível utilizar softwares e aplicativos que permitam a

criação e visualização de conteúdos de forma interativa e visual.

- **Auditivo** – Característica mais observadora, que aprendem por meio de transmissão auditiva de conteúdo ou discussões (KAYALAR; KAYALAR, 2017). Para auditivos, estratégias de ensino que envolvem a utilização de recursos auditivos são fundamentais para melhorar a retenção e a compreensão do conteúdo.

Tutores devem incorporar discussões em sala de aula, leituras em voz alta e palestras interativas para atender as preferências. A inclusão de debates e atividades em grupo em que os alunos possam verbalizar suas ideias e ouvir os contrapontos também é eficaz.

Além disso, o uso de recursos de áudio, como gravações de aulas, podcasts educativos e vídeos com narração, pode facilitar a assimilação. Ao incentivar os alunos, os educadores podem criar um ambiente de aprendizado mais envolvente e acessível para aprendizes auditivos.

- **Cinestésico** – Estilo de aprendizagem que tem facilidade em aprender com prática e experimentação (BEGEL; GARCIA; WOLFMAN, 2004). Nele é essencial incorporar atividades práticas e experiências diretas no ensino. Deve-se utilizar abordagens que envolvam movimento e manipulação de materiais, como experimentos de laboratório, atividades de construção, modelagem com materiais diversos e simulações.

Técnicas de ensino como dramatizações e exercícios relacionados ao conteúdo ajudam a manter os alunos engajados. Além disso, interrupções frequentes para atividades de alongamento ou pequenas dinâmicas podem ajudar a manter o foco.

Ao proporcionar um ambiente de aprendizado ativo e dinâmico, em que os alunos possam aprender fazendo, pode-se maximizar a eficácia do ensino para aprendizes cinestésicos.

- **Verbal** – Estilo de aprendizagem influenciado pelo uso da linguagem, preferência por leitura e escrita (PALLAPU, 2007). Neste caso, é importante incorporar estratégias que envolvam o uso intensivo de palavras, tanto escritas quanto faladas. Deve-se encorajar a leitura, a escrita e o debate como parte fundamental do processo de ensino.

Elaboração de ensaios, resumos e trechos de leitura podem ser altamente eficazes. Além disso, atividades como discussões em grupo, apresentações orais e leitura em voz alta ajudam esses alunos a processar e internalizar o material.

Utilizar recursos como livros e artigos também pode enriquecer a experiência de aprendizagem, sendo técnicas que beneficiam aprendizes verbais, facilitando uma compreensão mais profunda e duradoura dos conteúdos ensinados.

2.1.5 Teoria da instrução

Ainda no contexto de preferências no modo de aprendizado, o trabalho desenvolvido por Bruner (BRUNER, 1974) traz para o contexto da aprendizagem essa visão da necessidade de abordar conteúdos de formas diferentes.

O autor apresenta uma visão inovadora sobre a educação e o processo de ensino e aprendizagem, propondo que a aprendizagem é um processo ativo em que os alunos constroem novos conhecimentos a partir de suas experiências anteriores. Ele enfatiza a importância de uma abordagem estruturada e sequencial no ensino, em que os conceitos são apresentados de maneira que possam ser facilmente assimilados e conectados ao conhecimento existente do aluno.

A ideia é de que qualquer matéria pode ser ensinada de forma eficaz a qualquer criança, em qualquer estágio de desenvolvimento, se apresentada de maneira adequada. Ele sugere a utilização de uma espiral curricular, em que os temas e conceitos são revisitados repetidamente, com complexidade crescente a cada retorno. Essa abordagem permite que os alunos aprofundem sua compreensão e construam sobre o que já aprenderam, facilitando a aprendizagem contínua e progressiva.

Outra ideia central é a aprendizagem por descoberta, em que os alunos são encorajados a explorar, investigar e descobrir princípios por si mesmos. Ele acredita que esse método promove uma compreensão mais profunda e duradoura, pois os alunos se envolvem ativamente no processo de aprendizagem. A aprendizagem por descoberta estimula a curiosidade e a criatividade, permitindo que os alunos desenvolvam habilidades de resolução de problemas e pensamento crítico.

A teoria também enfatiza a importância da representação, argumentando que o conhecimento pode ser representado de três maneiras: ativa, icônica e simbólica. A representação ativa envolve a aprendizagem por meio da ação e da manipulação direta de objetos. A representação icônica utiliza imagens e gráficos para representar informações. A representação simbólica, que é a forma mais abstrata, usa símbolos e linguagem para descrever conceitos. Bruner sugere que o ensino deve progressivamente mover-se da representação ativa para a simbólica, acompanhando o desenvolvimento cognitivo do aluno.

Além disso, destaca-se o papel crucial da cultura e do contexto social no processo de aprendizagem (influência do meio em que se está inserido). Ele argumenta que a educação não ocorre isoladamente, mas é influenciada pelos valores, crenças e práticas culturais. Portanto, ele defende um currículo que reflita a diversidade

cultural e promova a compreensão intercultural.

Outro ponto importante é a ideia da motivação intrínseca na aprendizagem. Ele acredita que os alunos são naturalmente curiosos e motivados para aprender, e que o papel do educador é criar um ambiente que sustente e estimule essa motivação. Isso pode ser feito com atividades desafiadoras, mas atingíveis, que envolvam os interesses dos alunos e relevem suas experiências de vida.

As ideias tiveram um impacto significativo na teoria e prática educacional, oferecendo uma abordagem centrada no aluno que valoriza a descoberta, a representação progressiva do conhecimento e a influência do contexto cultural. Sua visão sobre a educação continua a inspirar educadores a criar ambientes de aprendizagem que sejam dinâmicos, inclusivos e orientados para o desenvolvimento cognitivo integral dos alunos.

Além deste, o trabalho de Herbert (1951) (THELEN, 1951) também já abordava a importância da teoria da instrução. O autor proveu a visão de aplicação no contexto experimental, e trouxe a visão desta abordagem dentro de um contexto real, em que foi possível observar outra visão da teoria de instrução, mas com o mesmo foco em abordagens educacionais como ferramenta de melhoria do ensino.


2.1.6 Taxonomia dos objetivos educacionais

Neste contexto, o trabalho organizado por Bloom e outros (BLOOM et al., 1956), que ficou conhecido com taxonomia de Bloom, estabeleceu uma estrutura hierárquica para categorizar objetivos educacionais e fornecer uma base para criação de currículos e avaliações. A taxonomia revisada de Bloom (KRATHWOHL, 2002) é dividida em três domínios principais: cognitivo, afetivo e psicomotor, embora o domínio cognitivo seja o mais amplamente utilizado e discutido.

O domínio cognitivo é composto por seis níveis de complexidade crescente, que podem ser vistos na Figura 2 e são: conhecimento, compreensão, aplicação, análise, síntese e avaliação. Cada nível representa uma etapa no processo de aprendizagem, começando com a memorização de fatos e terminando com a capacidade de julgar e criticar informações com base em critérios definidos.

- **Conhecimento:** é a base do domínio cognitivo e envolve a memorização de fatos, termos, conceitos e princípios. Os alunos devem ser capazes de lembrar informações específicas, como definições e datas importantes.
- **Compreensão:** este nível vai além da memorização, exigindo que os alunos interpretem, traduzam e extrapolem informações. Eles devem ser capazes de explicar conceitos em suas próprias palavras e compreender o significado das informações aprendidas.

Figura 2: Ilustração da Taxonomia de Bloom



Fonte: (SILVEIRA, 2023)

- **Aplicação:** aqui, os alunos usam os conhecimentos e compreensões adquiridos para resolver problemas novos e concretos. Este nível envolve a prática de habilidades e o uso do conhecimento em situações novas e diferentes.
- **Análise:** no nível de análise, os alunos devem ser capazes de decompilar informações em suas partes constituintes para entender melhor suas estruturas e relações. Isso inclui a identificação de padrões, a organização de partes em um todo coerente e a diferenciação entre fatos e hipóteses.
- **Síntese:** este nível requer a capacidade de combinar elementos distintos para formar um novo todo. Os alunos devem ser capazes de criar novas ideias, formular hipóteses e integrar diferentes conceitos de maneira inovadora.
- **Avaliação:** o nível mais alto do domínio cognitivo envolve fazer julgamentos baseados em critérios e padrões definidos. Os alunos devem ser capazes de criticar, avaliar e justificar suas opiniões e decisões.

O domínio afetivo da taxonomia de Bloom lida com as atitudes, valores e emoções dos alunos, estando portanto mais próximo do conceito de estilos de aprendizagem. Ele é composto por cinco níveis: recepção, resposta, valorização, organização e caracterização por um valor ou conjunto de valores. Este domínio destaca a importância de engajar emocionalmente os alunos no processo de aprendizagem, promovendo atitudes positivas e valores que sustentam o aprendizado contínuo.

- **Recepção:** Envolve a disposição dos alunos em prestar atenção a estímulos particulares e tomar consciência de sua importância.
- **Resposta:** Refere-se à participação ativa dos alunos em atividades de aprendizagem e sua reação aos estímulos recebidos.
- **Valorização:** Os alunos começam a atribuir valor e importância ao que estão aprendendo, desenvolvendo atitudes e preferências positivas.
- **Organização:** Neste nível os alunos integram novos valores em seus sistemas de crenças, criando uma organização coerente de valores.
- **Caracterização por um Valor ou Conjunto de Valores:** Os alunos demonstram um compromisso com valores específicos, que passam a influenciar seu comportamento de forma consistente.

O domínio psicomotor foi desenvolvido posteriormente e abrange habilidades motoras e físicas. Embora Bloom e seus colaboradores não tenham detalhado esse domínio inicialmente, outros pesquisadores o expandiram, incluindo habilidades como coordenação, destreza e manipulação de objetos.

A Taxonomia de Bloom teve um impacto duradouro na educação, fornecendo um guia estruturado para a definição de objetivos educacionais, desenvolvimento de currículos e avaliação de aprendizagem. Ela encoraja educadores a promover uma aprendizagem mais profunda e significativa, indo além da simples memorização para o desenvolvimento de habilidades de pensamento crítico e criativo. A revisão da taxonomia modernizou e expandiu o modelo original, mas a estrutura fundamental de Bloom continua sendo uma referência essencial na teoria e prática educacional.

2.2 Modelos de aprendizagem propostos

A partir dos estudos da psicologia e das formas de aprender variando com a personalidade de cada estudante, muitos autores pesquisaram o assunto e propuseram diferentes classificações de estilos. O objetivo destas abordagens não é apenas descrever as diferentes formas de aprender, mas também elencar características e ações que um tutor pode fazer para melhorar a sua forma de ensino e atingir com efetividade o seu público alvo.


Muitos modelos foram propostos na literatura, cada um deles buscando otimizar um conjunto de características de aprendizagem que trouxesse melhoria ao processo de ensino. No entanto, na inviabilidade de discutir todos neste texto, para este trabalho são destacados apenas os modelos de Kolb, Honey e Mumford, VARK e Felder e Silverman, discutidos a seguir.

2.2.1 Inventário de estilos de aprendizagem de Kolb

Um dos primeiros modelos formais sobre o tema é o Inventário de Estilos de Aprendizagem proposto por David Kolb (KOLB, 1976a). O modelo, conhecido como “Ciclo de Aprendizagem Experiencial”, descreve a aprendizagem como um processo cíclico composto por quatro estágios interligados: Experiência Concreta, Observação Reflexiva, Conceitualização Abstrata e Experimentação Ativa. Segundo Kolb, as pessoas aprendem melhor quando passam por todas as etapas do ciclo, o que permite uma compreensão completa e profunda do conteúdo.

Esse modelo enfatiza a importância da experiência direta e a reflexão sobre essa experiência como elementos centrais no processo de aprendizagem. A base do modelo de Kolb é dividida em quatro estágios de aprendizagem, como pode ser visto na Figura 3, adaptada de (IDKHAN; IDRIS, 2021).

Figura 3: Ciclo de aprendizagem e estilos de Kolb



Fonte: (IDKHAN; IDRIS, 2021)

Para o modelo, o processo de aprendizagem passa por estes estágios para a aquisição do conhecimento, entendendo que alguns indivíduos terão preferência, ou se adaptarão melhor, a alguns estágios específicos de acordo com suas características individuais. O processo é visto como interativo e contínuo, e os estágios são definidos como:

- Experiência Concreta (EC) - Estágio em que é favorecida a aprendizagem experimental;

- **Conceitualização Abstrata (CA)** - Esta fase marca preferência pelo pensamento analítico de conceitos para compreensão do tema;
- **Experimentação Ativa (EA)**- Fase marcada por processos do tipo tentativa e erro;
- **Observação Reflexiva (OR)** - Esta etapa é marcada pelo processo de reflexão e pensamento sobre o tema, sem ações ativas;

Entre os quadrantes há a formação de orientações bipolares, sendo a orientação vertical (eixo EC - CA) a dimensão relacionada à compreensão de conteúdo, e o eixo horizontal (EA - OR) ao processo de armazenar informações.

É possível observar que cada quadrante exibido na Figura 3, e formado pelos estágios, são marcados por orientações para estudo direcionado.

Entre os eixos exibidos anteriormente, o modelo define os estilos de aprendizagem personalizados e que melhor se adaptam às características comportamentais de preferência no processo de aprendizagem, como observar, sentir ou fazer.

Para determinar se um indivíduo pertence ao eixo específico, a proposta de Kolb tem como base a avaliação das respostas a 12 afirmações em um questionário, sendo que cada afirmação possui quatro alternativas de respostas que são pontuadas de acordo com uma escala de preferência.

Cada alternativa pontuada representa um dos quatro eixos, e a soma da pontuação final permite encontrar um quadrante de pertencimento dentro do ciclo. O Apêndice A detalha este processo.

Estes formam o conjunto de quatro estilos que fundamentaram a proposta deste trabalho, sendo eles:

- **Assimilador** – Este tipo é marcado pela preferência por receber o conteúdo e internalizá-lo por meio de observações e reflexões, sem desenvolver atividades ou ações;
- **Convergente** – O estilo convergente utiliza a conceitualização abstrata, realizando análise do conteúdo, associado a experimentação ativa, utilizando o conteúdo absorvido para realizar tarefas;
- **Acomodador** – Este estilo prefere realizar ações e ter uma postura mais ativa no aprendizado;
- **Divergente** – O estilo divergente busca associar os eixos de experiência concreta e observação reflexiva para construção de soluções criativas, adotando múltiplas estratégias e considerando soluções alternativas.

O modelo passou por processo de revisão e atualização do inventário de estilos (KOLB, 2007). A revisão manteve as quatro dimensões já conhecidas do modelo, mas ampliou a categorização dos indivíduos para nove diferentes tipos de estilos, sendo:

- Iniciador - Caracterizado pela capacidade de iniciar ações para lidar com experiências e situações. Envolve experimentação ativa (EA) e experiência concreta (EC).
- Experienciador - Caracterizado pela capacidade de encontrar significado a partir do envolvimento profundo na experiência. Baseia-se na experiência concreta (EC) enquanto equilibra a experimentação ativa (EA) e a observação reflexiva (OR).
- Imaginativo - Caracterizado pela capacidade de imaginar possibilidades observando e refletindo sobre experiências. Combina os passos de aprendizagem da experiência concreta (EC) e da observação reflexiva (OR).
- Reflexivo - Caracterizado pela capacidade de conectar experiência e ideias por meio do processo de reflexão. Baseia-se na observação reflexiva (OR) enquanto se relaciona com a experiência concreta (EC) e a conceituação abstrata (CA).
- Analítico - Caracterizado pela capacidade de integrar e sistematizar ideias por meio da reflexão. Combina a observação reflexiva (OR) e a conceituação abstrata (CA).
- Pensador - Caracterizado pela capacidade de desenvolver raciocínio abstrato e lógico. Baseia-se na conceituação abstrata (CA) enquanto mantém a experimentação ativa (EA) e a observação reflexiva (OR).
- Decisor - Caracterizado pela capacidade de usar teorias e modelos para decidir sobre soluções de problemas e cursos de ação. Combina a conceituação abstrata (CA) e a experimentação ativa (EA).
- Executor - Caracterizado por uma forte motivação para a ação direcionada a objetivos que integrem pessoas e tarefas. Baseia-se na experimentação ativa (EA) enquanto equilibra a experiência concreta (EC) e a conceituação abstrata (CA).
- Equilibrado - Caracterizado pela capacidade de se adaptar, ponderando os prós e contras de agir versus refletir e experienciar versus pensar. Equilibra experiência concreta, conceituação abstrata, experimentação ativa e observação reflexiva.

O modelo de Kolb se tornou um modelo conhecido na literatura e muito utilizado para validação em diferentes áreas do conhecimento, principalmente em sua forma mais simples de proposição, com os quatro estilos iniciais.

Para este trabalho se escolheu este modelo pela forma como a visão do tutor pode ser abordada para atender cada estilo, e pela viabilidade de trazer inovação associada a um modelo tradicionalmente conhecido, sendo uma boa forma de base de desenvolvimento da adaptação de conteúdo.

2.2.2 Modelo Honey e Mumford - LSQ

Outro modelo, o de Honey e Mumford (MUMFORD; HONEY, 1992), identifica quatro estilos principais de aprendizagem: Ativista, Reflexivo, Teórico e Pragmático. Cada estilo representa uma preferência distinta na forma como os indivíduos aprendem e processam novas informações, sendo:

- Os Ativistas são aprendizes que se envolvem diretamente em novas experiências. Eles são entusiastas, abertos a novos desafios e gostam de se lançar em atividades práticas. Ativistas preferem aprender com a prática e ação imediata, e tendem a evitar tarefas que exijam análise detalhada ou reflexão prolongada. Eles prosperam em ambientes dinâmicos em que podem experimentar e interagir com outros.
- Os Reflexivos preferem observar e pensar sobre as experiências antes de agir. Eles gostam de reunir dados e considerar diferentes perspectivas antes de tomar uma decisão. Reflexivos tendem a ser mais cautelosos e analíticos, valorizando a observação e a reflexão cuidadosa sobre o que aconteceu. Eles aprendem melhor quando têm tempo para pensar e analisar a informação antes de aplicá-la.
- Os Teóricos são aprendizes que gostam de entender os conceitos e modelos subjacentes às experiências. Eles preferem abordagens lógicas e estruturadas, e apreciam a oportunidade de explorar teorias e relacionar as novas informações a conhecimentos existentes. Teóricos são sistemáticos e gostam de analisar as causas e os efeitos, valorizando a coerência e a lógica em seu aprendizado.
- Os Pragmáticos são aprendizes práticos que gostam de ver como as ideias funcionam na prática. Eles são orientados para a aplicação e gostam de experimentar ideias e teorias para ver se funcionam no mundo real. Pragmáticos preferem abordagens que ofereçam resultados práticos e tangíveis e são mais motivados quando podem aplicar o que aprenderam a situações reais.

Os autores defendem que, embora cada indivíduo possa ter uma preferência dominante, a aprendizagem mais eficaz ocorre quando os indivíduos se envolvem em todas as quatro etapas do ciclo de aprendizagem: Experiência Concreta (Ativista), Observação Reflexiva (Reflexivo), Conceitualização Abstrata (Teórico) e Experimentação Ativa (Pragmático).

Este modelo destaca a importância de reconhecer e adaptar-se aos diferentes estilos de aprendizagem para maximizar o potencial de aprendizado e desenvolvimento pessoal. Ao entender suas próprias preferências de aprendizagem, os indivíduos podem buscar oportunidades que complementem seus estilos e também desenvolver habilidades em áreas menos familiares, promovendo uma abordagem mais equilibrada e holística para a aprendizagem.

Este modelo também é fundamentado em respostas a um questionário de estilos de aprendizagem (LSQ - Learning Style Questionnaire) (DUFF; DUFFY, 2002). O questionário foi desenvolvido como uma alternativa ao Inventário de Estilos de Aprendizagem (LSI) de Kolb. Criado para relatar as preferências de estilo de aprendizagem, o LSQ tem sido amplamente aplicado. Ele consiste em um inventário autoaplicável composto por 80 itens, cada um avaliado de forma binária (1 ou 0), a natureza normativa da escala faz do LSQ uma ferramenta atraente para pesquisadores educacionais.

Os itens do LSQ são predominantemente comportamentais, descrevendo ações que uma pessoa pode ou não tomar. Em alguns casos, um item pode investigar uma preferência em vez de um comportamento manifesto. Isso ajuda a capturar não apenas o que os indivíduos fazem, mas também suas inclinações naturais em situações de aprendizagem. A estrutura do questionário permite uma avaliação mais objetiva e comparável dos estilos de aprendizagem dos indivíduos, fornecendo indicativos sobre como eles preferem processar e internalizar novas informações.

O LSQ é projetado para identificar as forças relativas aos quatro diferentes estilos de aprendizagem: Ativista, Reflexivo, Teórico e Pragmático. Esses quatro estilos correspondem aproximadamente aos estilos de aprendizagem sugeridos por Kolb: experimentação ativa (Ativista), observação reflexiva (Reflexivo), conceitualização abstrata (Teórico) e experiência concreta (Pragmático). Além disso, o LSQ reflete duas dimensões independentes: Pragmatista-Teórico (apreensão) e Ativista-Reflexivo (transformação). Ao identificar e entender esses estilos, educadores e formadores podem adaptar suas abordagens de ensino para melhor atender às necessidades individuais de aprendizagem, promovendo uma experiência educativa mais eficaz e personalizada.

2.2.3 Modelo VAK/VARK

Além destes, o modelo VAK (FLEMING; MILLS, 1992), desenvolvido por Neil Fleming, é uma teoria de estilos de aprendizagem que classifica os estudantes em três categorias principais: Visual, Auditivo e Cinestésico. Este modelo propõe que cada indivíduo tem uma preferência natural por uma dessas modalidades, o que afeta como eles melhor processam e retêm informações. O objetivo do modelo VAK é ajudar educadores a adaptar suas metodologias de ensino para atender as diferentes necessidades dos alunos, promovendo uma aprendizagem mais eficaz e personalizada.

Os aprendizes visuais preferem receber informações por meio de imagens, gráficos, diagramas e outras representações visuais. Eles tendem a compreender e lembrar melhor o material quando ele é apresentado de maneira visual. Estratégias de ensino eficazes para esses aprendizes incluem o uso de mapas mentais, diagramas de fluxo, apresentações visuais e cores para destacar pontos importantes. Aprendizes visuais geralmente se beneficiam de anotações escritas e da observação de demonstrações práticas.

Os aprendizes auditivos assimilam melhor a informação quando ela é apresentada de forma oral. Eles aprendem de maneira mais eficaz com palestras, discussões, podcasts e leituras em voz alta. Esses indivíduos podem se beneficiar de métodos de ensino que incluem debates em sala de aula, gravações de áudio, e o uso de ritmos e músicas para ajudar na memorização de conceitos. A repetição oral e a discussão em grupo também são valiosas para os aprendizes auditivos, pois eles tendem a internalizar a informação quando a ouvem e falam sobre ela.


Os aprendizes cinestésicos preferem uma abordagem mais prática e baseada em atividades. Eles aprendem melhor por meio da experiência direta, do movimento e do toque. Para esses aprendizes é eficaz incorporar atividades físicas, experimentos práticos, dramatizações e outras formas de aprendizagem ativa. Eles se beneficiam de aulas que envolvem manipulação de objetos, projetos *hands-on*, e a prática de habilidades em situações do mundo real. A aprendizagem para os cinestésicos é mais eficaz quando eles podem estar fisicamente envolvidos no processo educativo.

Posteriormente, Neil Fleming expandiu o modelo VAK para o modelo VARK, que inclui uma quarta categoria: Leitura/Escrita. Este estilo adicional destaca a preferência por informações apresentadas em formato escrito, como listas, textos, manuais e apresentações escritas. Os aprendizes que preferem este estilo tendem a se beneficiar de materiais de leitura e escrita, como anotações detalhadas, glossários e livros-texto. O modelo VARK reconhece que muitos indivíduos podem ter múltiplas preferências ou uma combinação de estilos, proporcionando uma abordagem mais abrangente para entender e atender às diversas necessidades de aprendizagem.

O modelo VARK, ao incorporar a dimensão de leitura/escrita, oferece uma visão

mais completa e flexível das preferências de aprendizagem, permitindo que educadores criem ambientes de ensino que melhoram a retenção de conhecimento e o engajamento dos alunos. As diferentes possibilidades de ação neste modelo podem ser vistas na Figura 4. Este modelo tem sido amplamente adotado em contextos educacionais e de treinamento, ajudando a personalizar e melhorar as experiências de aprendizagem para uma variedade de alunos.

Figura 4: Modelo VARK



Fonte: (SANTOS, 2022)

2.2.4 Modelo de Felder e Silverman

O modelo de Felder e Silverman (FELDER, 2002) é amplamente utilizado para entender as diferentes maneiras como os alunos processam informações e aprendem de forma eficaz. Este modelo é particularmente popular no ensino de engenharia e ciências, mas também se aplica a outras disciplinas. Ele classifica os estilos de aprendizagem em quatro dimensões principais: ativa/reflexiva, sensorial/intuitiva, visual/verbal e sequencial/global.

Os aprendizes ativos preferem aprender fazendo. Eles tendem a se envolver em atividades práticas e experimentos, e aprendem melhor por meio de interação e discussão com os outros. Esses alunos gostam de trabalhar em grupo e de resolver problemas de forma colaborativa. Em contraste, os aprendizes reflexivos preferem pensar sobre a informação antes de agir. Eles aprendem melhor quando têm tempo para refletir e analisar os dados, muitas vezes preferindo estudar sozinhos e elaborar suas próprias conclusões antes de compartilhar com os outros.

A dimensão sensorial/intuitiva refere-se à preferência por dados concretos ou

abstratos. Os aprendizes sensoriais preferem fatos, dados concretos e métodos tradicionais. Eles gostam de resolver problemas usando abordagens bem estabelecidas e são detalhistas e práticos. Em contraste, os aprendizes intuitivos preferem conceitos abstratos, teorias e inovações. Eles gostam de desafios e de explorar novas possibilidades, tendendo a ser mais confortáveis com a abstração e a teoria do que com a memorização de fatos.

Os aprendizes visuais preferem informações apresentadas de forma gráfica, como diagramas, gráficos, tabelas e vídeos. Eles aprendem melhor quando podem ver uma representação visual dos conceitos. Em contraste, os aprendizes verbais preferem informações apresentadas em palavras, tanto escritas quanto faladas. Eles se beneficiam de leituras, palestras, discussões e explicações detalhadas.

A dimensão sequencial/global se refere à maneira como os alunos progredem por meio do material de aprendizado. Os aprendizes sequenciais entendem a informação de forma linear e lógica, aprendendo em pequenos passos e seguindo uma sequência ordenada. Eles preferem abordagens estruturadas e metódicas. Em contraste, os aprendizes globais tendem a aprender em grandes saltos, muitas vezes fazendo conexões de forma holística. Eles podem entender o conceito geral antes de dominar os detalhes e preferem ver o “quadro geral” antes de se concentrar nas partes individuais.

O modelo de Felder e Silverman é importante porque reconhece que os alunos possuem diferentes estilos de aprendizagem, que podem mudar dependendo do contexto e do material a ser aprendido. Ao compreender essas dimensões, educadores podem desenvolver estratégias de ensino mais eficazes e adaptáveis, que atendam às diversas necessidades de seus alunos. Isso pode incluir a criação de materiais didáticos que combinam elementos visuais e verbais, a incorporação de atividades práticas e reflexivas, e a estruturação de cursos que equilibram a sequência lógica com uma visão holística do conteúdo.

A citação a seguir, extraída de artigo escrito pelo próprio Felder, trata da importância de entender os estilos de aprendizagem, sendo:

“Uma aula em que os alunos estão sempre passivos é uma aula em que nem o experimentador ativo nem o observador reflexivo podem aprender de forma eficaz. Infelizmente, a maioria das aulas de engenharia se enquadra nessa categoria.” (Extraído de (FELDER, 2002), Tradução nossa)

Diante desta citação, percebe-se que a adaptação de um tutor ao método que melhor se adapta ao seu público-alvo é um importante caminho para o sucesso no ensino.

2.3 Críticas ao ensino baseado em estilos

Ao longo dos anos é possível encontrar vários críticos ao ensino baseado em estilos de aprendizagem, como é o caso de Nancekivell, Shah e Gelman (NANCEKIVELL; SHAH; GELMAN, 2020), que tratam esta linha de ensino como sendo um mito. Um trabalho que pondera de modo bastante detalhado os problemas envolvidos com estilos de aprendizagem é o de Coffield et al. (2004) (COFFIELD et al., 2004), que traz uma revisão sistemática de diferentes tipos de modelos e também aborda críticas a esta linha de pensamento.

No trabalho, os autores analisam detalhadamente 13 modelos, incluindo Kolb, Honey e Mumford, e o modelo VARK de Fleming, já citados anteriormente, porém listam outros 58 modelos, classificados em cinco grandes categorias. Neste estudo são avaliadas a base teórica, a validade empírica e a aplicabilidade prática desses modelos. Na revisão se critica que, embora muitos educadores e instituições adotem abordagens baseadas em estilos de aprendizagem, a evidência empírica que sustenta a eficácia dessas abordagens é muitas vezes fraca ou inconclusiva.

Destacam que, apesar da popularidade dos estilos de aprendizagem, há uma falta de consenso sobre definições claras e métodos de medição. Além disso, muitas das ferramentas de avaliação usadas para identificar os estilos de aprendizagem dos alunos carecem de rigor científico e confiabilidade. O livro também aborda a questão de que o foco excessivo em estilos de aprendizagem pode levar a uma categorização rígida e potencialmente limitante dos alunos, restringindo a flexibilidade e a adaptabilidade necessárias para enfrentar diferentes desafios educacionais.

Outra conclusão chave dos autores é a importância da diferenciação pedagógica, que envolve o uso de uma variedade de métodos e estratégias de ensino para atender às diversas necessidades e habilidades dos alunos. Em vez de rotular os alunos com estilos específicos, os autores defendem uma abordagem mais flexível e inclusiva que reconheça a complexidade e a diversidade do aprendizado.

Mesmo criticando muitas das abordagens e métodos populares, os autores identificam aspectos valiosos que podem ser utilizados para aprimorar a educação. Uma conclusão positiva é que a sensibilidade aos estilos de aprendizagem pode promover uma maior conscientização entre educadores sobre a diversidade de modos de aprendizagem entre os alunos. Reconhecer que os alunos possuem diferentes preferências e necessidades pode encorajar os professores a serem mais reflexivos e adaptáveis em suas práticas pedagógicas, levando a um ambiente de ensino mais inclusivo e receptivo.

A revisão destaca a importância da variedade na metodologia de ensino. Mesmo que a evidência não suporte a correspondência direta entre estilos de aprendizagem e métodos de ensino específicos, usar uma gama diversificada de estratégias

pedagógicas pode beneficiar todos os alunos. Diferentes abordagens, como aprendizagem ativa, visual, auditiva e cinestésica, podem ajudar a manter o engajamento dos alunos e a reforçar a compreensão por meio de múltiplas vias.

Além disso, os autores apontam que as teorias de estilos de aprendizagem incentivam os educadores a refletir sobre suas práticas e a inovar em suas abordagens pedagógicas. Essa reflexão pode levar ao desenvolvimento de métodos de ensino mais eficazes, que considerem as várias maneiras pelas quais os alunos processam e internalizam informações.

Outra conclusão positiva é a valorização do aprendizado personalizado. Embora a personalização baseada em estilos de aprendizagem específicos possa não ser sustentada empiricamente, a ideia de adaptar o ensino para atender às necessidades individuais dos alunos é válida. Essa personalização pode ser alcançada com a diferenciação pedagógica, em que os professores ajustam o conteúdo, o processo e os produtos de aprendizagem para maximizar o potencial de cada aluno.

2.4 Contexto de aplicação ao projeto

Diante do exposto neste capítulo, pode-se observar a importância do processo de fornecer conteúdo adequado a preferência do estudante, de forma que ele possa aproveitar melhor o conhecimento fornecido.

Para isso, é importante destacar que são necessárias várias adaptações do mesmo conteúdo para que se atenda os diferentes tipos de abordagem de cada estilo. Ao adaptar o conteúdo para atender a essas diversas preferências, os educadores podem tornar o aprendizado mais acessível e envolvente para todos os alunos.

Outro aspecto importante é a motivação e engajamento. Quando os alunos percebem que o material didático é relevante e adequado ao seu modo de aprendizagem, eles tendem a se sentir mais motivados e engajados. Isso pode levar a uma maior participação nas atividades de aula, um interesse mais profundo pelos tópicos estudados e uma disposição maior para enfrentar desafios acadêmicos.

A adaptação do conteúdo também promove a autonomia e a responsabilidade dos alunos sobre seu próprio aprendizado. Quando os alunos têm acesso a materiais de aprendizagem que se alinham com suas preferências, eles são mais propensos a assumir o controle de seu processo educacional. Isso pode incluir a seleção de atividades de aprendizagem que melhor correspondam às suas necessidades, a busca por recursos adicionais de forma independente e a autorregulação de seus estudos.

Além disso, a flexibilidade pedagógica proporcionada pela adaptação do conteúdo permite que os educadores respondam de maneira mais eficaz às dinâmicas e demandas variáveis da sala de aula. Cada turma tem suas próprias características e

desafios, e a capacidade de ajustar o material de ensino em tempo real pode ajudar os professores a manter a relevância e a eficácia de suas instruções.

2.4.1 Provendo a adaptação de conteúdo

Como tutor, prover o mesmo conteúdo adaptado de várias formas diferentes e direcionados a características específicas de cada estilo pode tornar o processo de preparação moroso ou mesmo inviabilizar esse atendimento.

O próprio processo de avaliação, seleção e produção de conteúdo feito por um tutor já é em si um trabalho complexo. Realizar este mesmo processo diversas vezes para adaptar as necessidades distintas traz um problema de escalabilidade para o tutor humano.

Por este motivo, a proposta deste trabalho se enquadra neste cenário, provendo o modelo de automatização da adaptação do conteúdo direcionada a diferentes estilos e aprendizagem.

Uma das críticas ao estilo de aprendizagem é a variabilidade das técnicas e a necessidade de flexibilização excessiva do tutor, inviabilizando o processo na prática. Com esta proposta, o tutor humano consegue obter seu conteúdo inicialmente preparado já adaptado para os tipos de alunos que os receberão.

2.5 Considerações finais

Este capítulo apresentou as teorias de aprendizagem e os fundamentos da pesquisa em estilos de aprendizagem. Neste contexto, foi possível observar a aplicabilidade do projeto e o cenário ao qual esta inserido. Também é possível considerar que proposta traz vantagens aos tutores humanos no apoio ao ensino, e viabiliza a aplicação dos experimentos em salas de aula.

Capítulo 3

Tratamento do conteúdo em sistemas tutores inteligentes

Neste capítulo se faz uma revisão das técnicas aplicadas na área, elencando as possibilidades e necessidades de novas aplicações. Para isto seu texto é apresentado abordando as técnicas existentes de tratamento de conteúdo em sistemas tutores.

É importante destacar que os dados aqui apresentados fazem parte de uma revisão sistemática construída inicialmente pela autora no ano de 2020 e revisada ao longo do desenvolvimento deste trabalho. Para este texto apenas os trechos de interesse do levantamento foram escolhidos, de forma que sua apresentação fosse direcionada aos pontos relacionados diretamente a este trabalho.

Visando mais clareza, cada seção abordará o que foi buscado no levantamento original, explicando o processo de escolha dos dados que compuseram este texto. Os trabalhos da revisão foram buscados entre os anos de 2010 a 2023, com requisitos de pesquisa específicos para os resultados alinhados.

3.1 Revisão sistemática

A revisão sistemática é um processo fundamental na pesquisa científica e na prática baseada em evidências, desempenhando um papel fundamental na síntese de conhecimento e na tomada de decisões informadas (AROMATARIS; PEARSON, 2014).

Diferente das revisões tradicionais, que podem ser subjetivas e menos rigorosas, a revisão sistemática segue uma metodologia rigorosa e padronizada para identificar, avaliar e sintetizar todas as evidências relevantes sobre uma questão específica. Esse processo garante a máxima objetividade e minimiza o viés, proporcionando uma base sólida para conclusões e recomendações.

Uma das principais importâncias da revisão sistemática é a validação da pesquisa existente. Ao compilar e analisar criticamente estudos de alta qualidade sobre um

determinado tema, as revisões sistemáticas oferecem uma visão abrangente do estado atual do conhecimento.

A transparência e reprodutibilidade são outros aspectos importantes das revisões sistemáticas. Ao seguir um protocolo predefinido e documentar detalhadamente todas as etapas do processo, as revisões sistemáticas permitem que outros pesquisadores repliquem o estudo.

Outra vantagem significativa é a identificação de lacunas na pesquisa e a orientação para futuras investigações. Isso ajuda a direcionar recursos e esforços de pesquisa para questões que ainda necessitam ser solucionadas, promovendo um avanço mais direcionado e eficiente do conhecimento científico.

Além disso, a revisão sistemática promove a integração de conhecimentos de diferentes estudos (POLLOCK; BERGE, 2018). Ao combinar dados de múltiplas fontes, as revisões sistemáticas aumentam o poder estatístico e a generalizabilidade dos achados, oferecendo *insights* mais robustos e abrangentes do que estudos individuais. Isso é particularmente valioso em campos em que os resultados de estudos isolados podem ser contraditórios ou inconclusivos.

Para este trabalho, a revisão sistemática foi a base para a proposição mais correta do ponto de atuação do projeto. As necessidades identificadas permitiram vislumbrar lacunas e contextos em que o projeto teria vantagens na sua aplicação.

A revisão realizada envolveu a primeira fase do projeto, em que foram avaliados sistemas tutores e o contexto da geração textual. Desta forma, a metodologia apresentada nos próximos capítulos foi fundamentada nos cenários observados.

3.1.1 Estudo complementar de outras revisões desenvolvidas na área

É possível encontrar outras revisões sistemáticas na área de pesquisa, principalmente relacionadas ao tema de tutores inteligentes. A observação de outras revisões permite entender o que já foi levantado de características, direcionando as respostas buscadas neste trabalho.

O trabalho desenvolvido por Mousavinasab et al. (MOUSAVINASAB et al., 2018) consiste em uma revisão sistemática sobre características dos sistemas e métodos de avaliação. Destaca-se desta pesquisa, o levantamento sobre os tipos de técnicas de inteligência artificial aplicadas, que, mesmo não sendo relacionadas a geração de conteúdo, permitem compreender as aplicações dentro do cenário.

Por outro lado, Han et al. (HAN et al., 2019) fornece uma revisão de 2006 a 2018 concentrando-se em tendências dos sistemas tutores. A pesquisa fornece uma visão geral de características do cenário, investigando o tipo de pesquisa realizada na área.

Em suas conclusões, esta pesquisa permite observar o número crescente de trabalhos que buscam novas técnicas e ferramentas para o sistema. Também destaca-se a observação sobre a presença de ensino adaptável e personalização para o usuário como técnica de aplicação.

Relacionados as aplicações de técnicas de inteligência nestes sistemas de ensino, é possível encontrar trabalhos como o desenvolvido por Wong e Looi (WONG; LOOI, 2012). A pesquisa investiga abordagens da técnica “Inteligência de Enxames” com relação a adaptação/individualização de ensino. O principal ponto da investigação é instigar o desenvolvimento desta técnica para sistemas tutores de ensino, ilustrando um novo ponto de pesquisa na área.

Além disso, destaca-se o trabalho de Korkmaz e Correia (KORKMAZ; CORREIA, 2019), com uma revisão sistemática de 2007 a 2017 sobre as tendências das pesquisas de aprendizado de máquina em relação a tecnologias educacionais. A revisão permite observar os tipos de técnicas investigadas e suas principais funções dentro do sistema, como categorização de arquivos e caracterização do usuário.

Nas pesquisas relacionadas as técnicas de geração e inferência em texto, destaca-se o trabalho de Janjanam e Reddy (JANJANAM; REDDY, 2019). O estudo desenvolvido investiga a sumarização de texto, uma importante aplicação de geração de conteúdo. Este levantamento permite a compreensão das técnicas e conceitos da sumarização automática, ilustrando um cenário de aplicação da geração de texto.

Por fim, a revisão sistemática construída por Zhang et al. (ZHANG et al., 2019) investiga o cenário atual para as técnicas de geração de texto, investigando os modelos e as aplicações existentes. O trabalho permite a visualização do funcionamento de diversas técnicas aplicadas a geração.

A observação de outras revisões da área permite uma visão geral do campo de pesquisa e fundamenta a necessidade da atividade de revisão realizada previamente a este projeto, direcionada as necessidades da proposta.

3.1.2 Estratégia de busca

As bases de busca foram escolhidas pela relevância de conteúdo e disponibilidade dos dados que estavam sendo buscados. Um levantamento inicial sobre a pesquisa permitiu observar quais as bases de informações seriam aplicáveis. Os números obtidos em cada base serão abordados neste texto. As escolhidas foram:

- IEEE ¹
- ACM ²

¹<https://www.ieee.org/>

²<https://dl.acm.org/>

- Science Direct ³
- Taylor and Francis ⁴

De acordo com as necessidades e quantidade de trabalhos disponíveis em cada base de dados, a pesquisa realizou busca direcionada para títulos ou pontos do texto, dependendo de cada situação.

Pelo número de trabalho disponíveis na base do IEEE, a melhor estratégia de pesquisa é a aplicação de busca por termo exclusivamente no título, como Intelligent Tutor, Artificial Intelligence, Generation, o que refina e direciona os dados levantados de acordo com o objetivo.

Já para as bases ACM e Taylor and Francis, a melhor estratégia é a busca de termos chave no título, como Intelligent Tutor, Artificial Intelligence, Generation, e termos acessórios, como text, content, em pontos do texto. Apesar de aumentar a variabilidade dos resultados e exigir uma maior filtragem na análise, esse modelo de pesquisa permite aproveitar os melhores resultados da base.

Por fim, para a base Science Direct o refinamento é melhor quando os termos chave são buscados em Títulos, abstract e palavras-chave, garantindo que não haverá perdas durante a filtragem.

Para responder os questionamentos, foram feitas consultas a partir de termos chave que se enquadravam no perfil do trabalho, sendo escolhidas de acordo com o número de trabalhos com as informações.

Os modelos de termos chave abordados no texto estão em seu modelo básico. É importante ressaltar que caracteres especiais para buscas na base foram adicionados de acordo com o regramento de cada uma delas. Por exemplo, foram realizadas buscas com o termo “system” e “system*”, dependendo se a base automaticamente procuraria as versões em plural ou se aguardava a inserção de caractere (*) indicando variabilidade.

Os resultados exibidos nesta seção já foram filtrados pelo período de publicação (2010-2023), na qual a motivação de escolha do tempo é abordada na seção “Critérios de Seleção”.

Em um primeiro momento, a sugestão de string possuía uma versão mais completa de pesquisa (Tabela 1), o que levou a um cenário complexo de resultados (Tabela 2).

A quantidade de resultados obtidos na Tabela 2 inviabiliza a análise de tema pelo quantitativo de trabalhos. A partir da observação dos resultados, concluiu-se que o termo “Learning” indicava resultados de outras linhas de pesquisa, e que a busca por termos de tutores inteligentes seria a filtragem mais efetiva.

³<https://www.sciencedirect.com/>

⁴<https://www.tandfonline.com/>

Tabela 1: Primeira versão de termos chave para tutores inteligentes

(Intelligent tutoring systems OR Intelligent Tutor OR Learning)	AND
(content OR text OR subject)	AND
(generation OR recommendation)	

Tabela 2: Resultados na primeira versão de termos chave para tutores inteligentes

Base de Dados	Resultados
IEEE	4052
ACM	5170
Taylor and Francis	5567
Science Direct	5089

Também foi observado que a aplicação dos termos acessórios, como “text”, causava um direcionamento excessivo e excluía alguns resultados importantes para a pesquisa.

Por este motivo, uma nova chave de busca foi definida (Tabela 3), e os resultados refinados (Tabela 4).

Tabela 3: Versão final de termos chave para tutores inteligentes

(Intelligent tutoring systems OR Intelligent Tutor)	AND
(generation OR recommendation)	

Tabela 4: Resultados na versão final de String para tutores inteligentes

Base de Dados	Resultados
IEEE	130
ACM	25
Taylor and Francis	119
Science Direct	44

Com a chave de busca definida (Tabela 3), é possível observar o refinamento dos resultados, o que direcionou a revisão para os objetivos do cenário específico que deve ser compreendido, deixando a escolha definitiva para o processo de análise dos resultados.

3.1.3 Critérios de seleção

Alguns critérios de seleção foram estabelecidos para construir um filtro, em que apenas os trabalhos mais semelhantes a linha desta pesquisa pudessem se encaixar para a avaliação final.

Foram escolhidos apenas trabalhos entre 2010 e 2023, para que o resultado reflita um cenário atualizado de projetos e aplicações.

O procedimento de seleção seguiu com análise de tema e resumo da pesquisa

para identificação do conteúdo, e também com avaliação das conclusões para um melhor entendimento.

Por fim, foi feita a remoção de temas duplicados e que não se encaixavam na pesquisa.

No cenário de tutores inteligentes foram escolhidos 63 trabalhos para a revisão final, sendo divididos conforme a Tabela 5.

Tabela 5: Trabalhos selecionados no cenário de tutores inteligentes

Base de Dados	Resultados
IEEE	34
ACM	7
Taylor and Francis	9
Science Direct	13

A concentração de trabalhos na base de dados do IEEE que fizeram parte da primeira seleção (resultado da string), justifica o número elevado de escolhas feitas pela análise. Ainda assim, as outras bases apresentaram resultados relevantes para pesquisa, indicando a validade da escolha como fontes de pesquisa.

É importante destacar que a revisão sistemática foi trabalhada com mais de um tema, investigando também métodos generativos de inteligência artificial. No entanto, a parte apresentada neste trabalho é apenas a que esta relacionada ao cenário em que se propôs a solução do projeto.

3.2 Extração de dados

A extração de dados buscou respostas para 7 variáveis nas pesquisas, necessárias para elencar as principais características presentes nos trabalhos e responder as questões centrais.

- Área de concentração (Educação, comercial, entre outras)
- Objetivo central
- Técnica aplicada
- Propósito da técnica
- Vantagens diferenciais
- Método de Avaliação
- Performance

3.3 Resultados obtidos - Sistemas tutores inteligentes e técnicas para produção de conteúdo

Nesta revisão se buscou identificar o que é aplicado em sistemas tutores para criar variação no conteúdo abordado. Já era perceptível nas pesquisas que os sistemas utilizavam recomendação de conteúdo, mas, ainda assim, o levantamento buscou esclarecer todas as frentes de abordagem.

Os resultados puderam ser separados em quatro áreas de atuação, sendo:

1. Sistemas de Recomendação: Este modelo de sistema é o mais frequente nos resultados, buscando construir a adaptação do conteúdo por meio da recomendação de temas.
2. Preparação de Conteúdo: Neste caso, busca-se uma adaptação no formato do conteúdo apresentado.
3. Geração de Questões: A geração de questões também é um método de produção do conteúdo, possuindo formato direcionado para interação com perguntas e respostas.
4. Identificação de Perfil de Usuário: Soluções nessa categoria buscam identificar o perfil para que o conteúdo seja apresentado de forma mais adequada.

Para a área de definição deste trabalho os sistemas de recomendação e de geração de questões são os mais relevantes. Esta escolha se deve à manipulação de conteúdo feita nestas áreas, se aproximando da proposta do projeto. Por este motivo, apenas os resultados destas duas áreas serão destacados nesta seção.

3.3.1 Sistemas de recomendação

Os sistemas de recomendação estiveram mais presentes entre os resultados, refletindo o cenário atual dos tutores inteligentes, que em sua maioria utiliza recomendação para adaptação do ensino.

Os trabalhos abordados nesta seção têm como objetivo principal desenvolver técnicas que melhorem a sua capacidade de recomendação de conteúdo, aumentando a capacidade de ensino na adequação do sistema.

Aplicação de coleta automatizada de características dos usuários

1. Recomendação por extração de características (Educação / Geral) (ZHIPING; YU; TIANWEI, 2011) - Recomendação de conteúdo direcionado aos dados e informações extraídas individualmente dos usuários. Construída por meio de

criação de modelo de usuário, *queries* e domínio de conhecimento / Conhecimento sobre a utilização e preferências do sistema.

Realizada uma avaliação formal dos sistemas e produzida uma página de navegação *Web* com conteúdo recomendado e abordagem de relacionamento entre conceitos.

2. Recomendação de vídeos para ensino de Inglês (Educação / Línguas) [(ZHANG et al., 2015)] - Criação de modelo de usuário para recomendação de vídeos e aplicação de testes de acordo com o modelo estabelecido de usuário. O módulo de vídeo e recomendação permite o ensino direcionado, com categorização de conteúdo amplo em vídeo.

É avaliada a ferramenta, e destaca-se que a aplicação de ferramentas de recomendação e análise de usuário permite direcionar o conteúdo de uma forma adequada, apoiando o sistema.

3. Recomendação de conteúdo com aplicação de LIME (Educação / Geral) (CORBI; BURGOS, 2015) - Aplicação da técnica LIME (Learning, Iteration, Mentoring e Evaluation) para modelagem de características do usuário, para que seja executada a filtragem nos dados coletados visando preparar o processo de recomendação/perfil. A montagem da técnica permite manter um conjunto de dados sobre a utilização do sistema e aplicá-los na ferramenta de recomendação.

São feitas execuções do modelo para teste e avaliação. O projeto permite aplicar filtragem sobre os dados e categorias, o que permite uma efetiva recomendação direcionada.

4. Recomendação em sistema E-learning (Educação / Redes de Computadores) [(VERDÚ et al., 2014)] - Proposta de extensão com técnica de recomendação e assistência monitorada. A aplicação da técnica no ambiente permite um monitoramento do conteúdo avaliado pelo usuário. Com a avaliação de conteúdo e experiência de comunicação/assistência é possível um controle sobre a utilização da aplicação.

Foi feita a avaliação da ferramenta proposta e é importante destacar que o trabalho descrito permite adaptação para outro tipo de sistema, e suas recomendações de conteúdo servem de apoio para adaptação dos sistemas.

5. Indicação de artigos para leitura (Educação / Literatura) (HSU; HWANG; CHANG, 2010) - Estratégia de identificação de características e pontos de preferência. A técnica desenvolvida permite identificar vários pontos de verificação, para que possa ser escolhido um ramo do domínio de informações.

A escolha do artigo melhor adaptado incentiva o processo de aprendizagem, e direciona para o conteúdo mais colaborativo com o ensino.

Com a avaliação da técnica, os resultados indicaram que a escolha adaptada foi motivo de incentivo ao ensino, melhorando as técnicas de abordagem para os alunos.

6. Módulo de diagnóstico de aprendizado para indicação de conteúdo (Educação / Geral) (DAI; QIU; ZHANG, 2021) - Sistema que possibilita mapear o conhecimento dos alunos, identificando lacunas e pontos fortes através da análise de seus desempenhos e interações. A partir de um grafo de conhecimento, o sistema pode diagnosticar de forma precisa as áreas onde o aluno precisa de mais suporte. Com base neste diagnóstico, ele recomenda recursos de aprendizagem específicos.

A avaliação de utilização demonstrou que a ferramenta conseguiu atingir os níveis de personalização e recomendação esperados da observação de características.

Aplicação de técnicas autorais

7. Recomendação de conteúdo a partir da aplicação do método SKP-LS (Educação / Computação) (YAN et al., 2017) - Aplicação do método SKP-LS (descrição personalizada do estado de aprendizagem - método do autor) para construção de arquitetura de sistema para inferência sobre as variáveis SPK, e recomendação de conteúdo e exercícios personalizados. Coletando dados e avaliando performance em tempo-real, com recomendação baseada nas necessidades apresentadas durante o aprendizado.

São avaliados os resultados coletados de SPK para alunos durante teste e recomendação de conteúdo no cenário. A relação entre as informações de SPK e a indicação de conteúdo fornecida condizem com a expectativa do usuário, mostrando adaptação ao sistema.

Aplicação de métodos com grafos ou clusterização

8. Método de recomendação com redes Bayesianas aplicado a coleta de características (Educação / Geral) (KOZIERKIEWICZ-HETMAŃSKA, 2011) - Modificação de cenários de aprendizagem com Redes Bayesianas aplicadas as características coletadas em outros módulos. Permite a construção de um cenário de aprendizagem recomendado de forma personalizada, realizando a

geração de ambiente com base em informações já coletadas pelo sistema, seguindo protocolo da arquitetura.

Com construção de prova formal do teorema que afirma sobre a melhora no aprendizado com cenários adequados, a arquitetura do sistema proposto é completa e permite a aplicação da personalização neste modelo de ensino, com divisão em módulos e interpretação de características por redes neurais.

9. Recomendação de conteúdo a partir de dados da técnica K-means (Educação / Matemática) (TROUSSAS; KROUSKA; VIRVOU, 2019) - Recomendação de conteúdo personalizado a partir de características coletadas e aplicação da técnica K-means no agrupamento e indicação de conteúdo a partir dos grupos. Além da aplicação do algoritmo há uma interação dinâmica com o usuário, visando melhorar a adaptação do sistema.

Avaliação de utilização por público alvo, e geração de software visual e bem aceito nos testes, alcançando o objetivo de adaptação automática e recomendação.

10. Recomendação com base em Tags (Educação / Geral) (KLAŠNJA-MILICEVIC et al., 2012) (KLAŠNJA-MILIĆEVIĆ; VESIN; IVANOVIĆ, 2018) - Agrupamento de características e construção de avaliação das tags indicadas. O agrupamento permite organizar as características de aprendizagem, e a partir da avaliação de tags inseridas é feita uma recomendação de conteúdo pela ferramenta. Esta avaliação por tags permite a criação de um meio simples e adaptável para recomendação de conteúdo, e o agrupamento aumenta a taxa de acerto da ferramenta.

A avaliação da proposta verifica que o modelo permite a personalização de conteúdo e é uma técnica que pode ser adaptada em diversos sistemas.

11. Recomendação com aplicação de Redes Bayesianas (Educação / Computação) (ALDAY, 2018) - A proposta aborda recomendação de conteúdo com base na performance, com aplicação de redes Bayesianas. A técnica extrai do modelo de estudante construído as informações de performance, o que permite a recomendação.

A proposta permite um maior controle sobre a recomendação com a aplicação de algoritmos inteligentes, ampliando a área de atuação.

É realizada a avaliação da técnica, o que permitiu a observação do controle que pode ser realizado pelo sistema, por meio da análise de performance.

12. Agente conversacional pirolístico para ITS (Educação / Geral) (SOSNOWSKI; YORDANOVA, 2020) - Desenvolvimento de aplicação do tipo chatbot para

interpreta e responder no processo de interação com estudantes. a proposta combina as técnicas de NLP com modelo probabilístico em redes bayesianas.

A avaliação comparativa inclui o trabalho as categorias de similaridades com ferramentas de reconhecimento de ações e estado.

Aplicação modelos de regressão/análise de dados ou lógica Fuzzy

13. Sistema tutor com análise de sentimentos e recomendação (Educação / Geral) [(MEENAKSHI et al., 2017)] - Aplicação de técnica de regressão logística e API de recomendação, permitindo a produção de instruções recomendadas com base na avaliação do modelo e extração de conteúdo do YouTube. A integração proposta permite reduzir a introdução manual de conteúdo na ferramenta, permitindo a ligação com a API.

Com a avaliação da arquitetura proposta ao sistema, o trabalho alcança um aumento da personalização neste tipo de sistema, colaborando para o aperfeiçoamento.

14. Recomendação com SCORM e análise de usuário (Educação / E-learning) (DAOMIN; MINGCHUI, 2013) - Aplicação de SCORM e algoritmos de análise de usuário para construir um modelo de usuário e praticar inferência sobre a utilização do sistema para recomendação em ambiente E-learning. A proposta considera as habilidades cognitivas na recomendação de conteúdo, o que leva a um melhor conhecimento do usuário.

É feita uma avaliação formal da aplicação dos algoritmos, e observa-se que a aplicação de algoritmos fuzzy para elaboração da capacidade cognitiva é uma proposta viável para a recomendação em sistemas tutores, melhorando a capacidade do sistema.

15. Recomendação personalizada com CBR (Educação / Algebra) [(MASOOD; MOKMIN, 2017)] - Identificação de características do usuário e estilos de aprendizagem, seguida de aplicação da técnica CBR (Case-Based Reasoning) para escolha seletiva do tipo de material a ser exibido. A análise feita em tempo de execução permite aumentar o desempenho dos usuários e a adequação do sistema.

A avaliação da ferramenta permite verificar o comportamento esperado da técnica, destacando também direcionamentos futuros para melhoria no processo de identificação de perfil.

16. Recomendação com análise CCF (Educação / Geral) (HUO; XIAO; NI, 2018) - Construção de recomendação com base em características com CCF (Classificação e análise de características de contexto). A técnica propõe análise de dados em uma base de estudantes para construir recomendação de exercícios. Este tipo de inferência aplicada a bases de dados permite visualizar o contexto dos sistemas tutores, possibilitando aplicação.

A avaliação comparativa ilustra que foi possível interpretar os dados da base e obter estratégias de recomendação que possam ser aplicadas no cenário de aprendizagem, mostrando a eficiência da técnica.

17. Mineração de dados para recomendação (Educação / Geral) (JUGO; KOVAČIĆ; SLAVUJ, 2014) - Integração entre sistema ITS e técnica de mineração de dados para recomendação. Neste cenário, é feita a análise dos dados produzidos para prover recomendação de conteúdo em ITS como resultado. A técnica permite um aprimoramento para o funcionamento do sistema tutor, trazendo o benefício do conteúdo personalizado.

Da avaliação da proposta, observa-se que a proposta e o modelo de integração permitem uma visualização do cenário de aplicação, incentivando a pesquisa para ITS.

18. Aplicação de técnicas de IA para resolução de problemas matemático (Educação / Matemática) (WU et al., 2022) - Geração automática de tutorias de solução para problemas matemáticos recebidos como entrada, produzindo textos e explicações do passo a passo da resolução. As soluções são transformadas em itens sequenciais, podendo ser adaptadas a necessidade do usuário.

A avaliação da proposta demonstrou resultados positivos na utilização, incluindo módulo de produção de feedback da resolução dos exercícios.

19. Sistema educacional inteligente com base em CBR (Educação / Geral) (BORHADE et al., 2023) - A estratégia da proposta é utilizar a tecnologia de captura do uso de IoT na observação do comportamento dos estudantes e registro durante a utilização, aliado com técnicas CBR para aprimorar a experiência de aprendizagem.

A avaliação da proposta indicou melhoria no processo de aprendizagem, observada durante o monitoramento, e também agilidade no processo de aprendizagem e estudo.

Aplicação de monitoramento por sensores

20. Recomendação com base em dados de sensores (MDP) (Educação / Geral) [(LIU et al., 2018)] - Sistema de recomendação em sala de aula inteligente, com proposta de aplicação futura em sistema inteligente de aprendizagem. A análise dos dados coletados e do processo de decisão Markov, aprendizado por reforço, é a base para a recomendação. Com isso, a proposta permite uma recomendação com base na análise de cenário, o que melhora a taxa de acerto das adaptações recomendadas.

Com a avaliação da proposta, o modelo permite uma visão do cenário para aplicação em sistemas inteligentes com interação, e valoriza a necessidade de recomendação para melhora na adaptação de conteúdo e aprendizagem.

3.3.2 Geração de questões

As técnicas de geração de questões trazem grandes vantagens para o cenário de aplicação. A capacidade de produzir questionamentos e respostas com técnicas de filtragem de dados eliminam esforço humano e permitem uma maior escalabilidade na investigação do conteúdo.

Existem diversas propostas de geração automatizada, visando sempre aprimorar a capacidade de gerar questões eficientes e de acordo com o nível de dificuldade de cada usuário.

Técnicas extrativas de geração

21. Geração de questões de múltipla escolha (Educação) (SHAH; SHAH; KURUP, 2017) - Aplicação de gerador de questões em base de dados Wikipédia. Para o processo, é feita uma filtragem de informações da base e seleção de conteúdo adequado para montagem de perguntas. A proposta permite gerar questões sem a interferência humana, o que apoia os cursos produzidos em grandes volumes.

A avaliação da acurácia do conteúdo verifica a possibilidade de geração de questões com boa acurácia a partir de dados textuais.

22. Geração adaptada de questões com Redes Bayesianas (Educação) (KHODEIR et al., 2014) - As redes permitem a geração de questões e respostas para construir um modelo de conhecimento do estudante. Com isso, é possível a automatização das tarefas de identificação em domínios probabilísticos.

Com a avaliação da técnica, observou-se que os resultados indicaram vantagens na aplicação do método em relação a identificação das características dos

usuários.

23. Geração automática de questões em língua portuguesa (Educação) (LEITE et al., 2020) - Esta proposta utiliza técnica de NLP para obter a construção automática de questões em língua portuguesa. O processo de geração de perguntas inclui a compreensão do conteúdo do texto, a identificação de informações relevantes e a construção de perguntas gramaticalmente corretas e coerentes.

A avaliação foi realizada com professores em um projeto piloto, em que este respondiam as perguntas, e os resultados foram promissores para aplicação da proposta dentro do ensino.

Técnicas com avaliação de ambiente

24. Geração de questões e guias com base na análise de expressões faciais (Educação / Programação) (TIAM-LEE; SUMI, 2018) - Detecção facial de expressão de confusão. Com base na detecção facial de confusão, o gerador de questões oferece guias e apoio para resolução de exercícios. O uso de reconhecimento facial permite um comportamento ativo do sistema a partir desta identificação, o que melhora a experiência do usuário.

Realizada a avaliação da ferramenta, a proposta permite construir os exercícios de diferentes modos e fornecer o apoio ao usuário na realização, o que é um panorama completo para aplicação nos sistemas tutores.

25. Geração de questões com análise de cenário (Educação) (SINGHAL; GOYAL; HENZ, 2016) - Análise de valores de entrada e fatores definidos sobre o nível de dificuldade para produzir a questão automaticamente. A possibilidade de gerar questões de forma automática é uma grande vantagem e pode ser aplicada dentro das atividades de um sistema tutor, apoiando a geração de conteúdo.

A avaliação da ferramenta mostrou a capacidade de gerar questões niveladas pela dificuldade e guiadas por assunto, alcançando bons resultados.

3.3.3 Avaliação do levantamento

Os resultados aqui apresentados mostram que a maior parte dos trabalhos está relacionada à recomendação de conteúdo. Embora sejam usadas técnicas diversas para isto, o mais próximo de uma produção efetiva de conteúdo é a geração de questões, construída a partir de informações e trechos dos dados. Esta outra forma de colocação dos dados tem um resultado positivo para apoio ao ensino, refletindo que estes métodos de geração são desejáveis à área.

Esta observação permite entender a necessidade de técnicas de geração de conteúdo automatizado nestes sistemas, o que melhorará a capacidade de ensino e escalabilidade na produção.

Sistemas de Recomendação

Para exemplificar o processo de adaptação e como este pode ser aplicado, é possível observar o trabalho desenvolvido por Lavbic et al. (2017) (LAVBIČ; MATEK; ZRNEC, 2017), que buscou preparar um sistema de dicas para apoio ao usuário, se adaptando para as necessidades no aprendizado de Structured Query language (SQL).

Em um primeiro momento, definiu-se a área de aplicação do trabalho como ensino de linguagens de programação. Por SQL ser uma linguagem importante, os autores pontuaram que fornecer suporte adaptado durante a realização de exercícios aumentaria a capacidade de aprendizagem, utilizando dicas geradas automaticamente e variando de acordo com o nível de cada usuário.

A proposta do trabalho utiliza os exercícios já realizados por alunos para gerar as dicas que serão fornecidas. Ao completar um exercício, a solução é armazenada e será fornecida como composição da dica para os próximos alunos.

O modelo utilizado é o Markov Decision Process (MDP), a técnica recebe os dados das soluções anteriores com entrada e realiza o processo de geração de dicas a partir deles. A definição da tupla para o MDP é composta de um grupo com cinco variáveis, que são: Estados, ligações entre os estados, matriz de transição de probabilidades, função de recompensa, e fator de desconto. A composição permite a avaliação de otimização da função, buscando a melhor escolha de estados.


Para armazenar informações, as entradas de resolução foram organizadas em formato de árvore, assumindo que a construção de resposta do aluno segue uma ordenação para construção. Esta estrutura é enviada para o modelo MDP como estados.

O modelo produzido pelo MDP pode ser visto como exemplo na Figura 5.

Ao solicitar uma dica, a entrada do aluno é fornecida como entrada no modelo MDP, e a estrutura buscará o estado mais compatível para fornecer a solução. As estruturas são convertidas e avaliadas como árvores, e as comparações utilizam algoritmo de critério de distância.

O projeto destaca algumas limitações como o fato de uma alteração na estrutura de uma query poder afetar a comparação; e também sobre assumir uma ordenação na produção da cláusula que será armazenada na árvores. Ambos podem gerar falhas no comportamento da solução, porém não afetaram significativamente o resultado dos testes.

Figura 5: Modelo de grafo MDP



Fonte: (KORKMAZ; CORREIA, 2019)

Como conclusão, foi construído um sistema em versão Web para teste com usuário. Estes foram divididos em segmentos de acordo com o cenário, como: usuários com e sem conhecimento, ou que aplicaram ou não as dicas, entre outras.

As avaliações foram adequadas, mostrando que a aplicação das dicas diminuiu a dificuldade dos estudantes em se aproximar da solução correta, melhorando a efetividade do ensino. Ainda que a estrutura de árvores seja mais simplista, a proposta sugere melhorias no algoritmo para eliminação deste problema.

Geração de Questões

O trabalho desenvolvido por Shah et al. (2017) (SHAH; SHAH; KURUP, 2017) buscou a automação do processo de geração de questões, de forma que a partir de uma base definida, todo o processo de filtragem e criação das questões fosse automatizado e sem interferência humana, o que torna a aplicação mais escalável para seus usuários.

Primeiramente, para a aplicação das técnicas é necessário definir o modo de trabalho e modelo de questões que devam ser produzidas. Este trabalho propõe a produção de questões do tipo “Multipla escolha”, pela facilidade para os executores do teste e facilidade de correção, uma vez que há definição do escopo de respostas.

Além disso, o projeto escolheu uma arquitetura formada de duas partes principais: a base de conhecimento e a geração de questões, que são detalhadas a seguir:

1. Base de Conhecimento - Toda a base de conhecimento é formada a partir de extrações do Wikipédia. Foram separadas URLs de artigos na referida página e separados em tópicos de acordo com a área do trabalho.

A base de conhecimento é composta por:

- Lista de tópicos, formados pelas URLs de entrada;
- Texto e arquivos HTML, extraídos por API específica;
- Palavras-chave extraídas dos arquivos HTML, estas são fundamentais para o trabalho, indicando quais termos pode compor a formação da questão. As palavras são divididas em unigramas e bigramas para melhor processo de execução, sendo que também ocorre a montagem do dicionário de palavras nesta etapa;
- Dicionário com pesos, o dicionário de palavras recebe a aplicação do algoritmo de frequência inversa (IDF) que permite pontuar a probabilidade de ocorrência e importância de um termo. A partir deste momento, as palavras-chave são armazenadas juntamente com seus pesos atribuídos;
- Arquivo de texto simples, construídos a partir da junção do texto de todos os tópicos, que serve como base para determinar alternativas candidatas;
- Lista de possíveis candidatas para cada termo, em que para cada termo chave, serão indicados termos candidatos para serem colocados em alternativas. O processo de escolha dos termos alternativos utiliza a técnica de análise com base no contexto. Neste método, para cada termo escolhido, são elencados outros termos alternativos que são adequados ao mesmo contexto, esta coleção de texto alternativo é o que apoia a formação das alternativas como resposta a questão.

2. Geração de Questões - Efetivamente o módulo principal do modelo, recebe como entrada um parágrafo do texto e produz como resultado a questão e suas alternativas. O processo pode ser separado em cinco fases, explicadas com exemplos a seguir:

- Um parágrafo de texto puro é fornecido a ferramenta, como exemplo um texto de física (Figura 6);
- O processo de tokenização de sentenças é feito na amostra;
- Nesta etapa, as sentenças que não são candidatas para compor um modelo de questão são removidas. O projeto remove trechos com marcação de discurso, como ‘Thus’, ‘This’, ‘Also’, ‘So’, ‘And’, ‘Since’, entre outros, que normalmente não trazem dados suficientes para compor uma questão, sendo apenas complementação de contexto.

No caso, o trecho: “This is really a statement about its internal kinetic energy”, será removido.

Figura 6: Modelo de entrada de texto

```
Heat is a form of energy transfer. Materials do
not contain heat. They contain internal energy that
can be transferred from one body to another.
Internal energy is the vibrating and rotating and
general jostling of atoms and/or molecules that make
up the 'thing,' whether it is wood, steel, water.
One way to measure the heat of an object is to
measure its temperature. This is really a statement
about its internal kinetic energy.
```

Fonte: (SHAH; SHAH; KURUP, 2017)

- Na próxima fase, os trechos são divididos em unigramas e bigramas, e serão comparados com o dicionário produzido na base de conhecimento. A partir do termo chave e da pontuação IDF, a questão é escolhida e o termo resposta definido.

A Figura 7 exemplifica o processo criado para a primeira frase da entrada. No caso, o termo 'energy transfer' possui maior pontuação IDF para o contexto, e é escolhido como resposta correta ao preenchimento da questão;

Figura 7: Modelo de texto avaliado para a questão

```
Heat is a form of energy transfer.

List of Unigrams:
{'Heat', 'is', 'a', 'form', 'of', 'energy',
 'transfer'}

List of Bigrams:
{'Heat is', 'is a', 'a form', 'form of', 'of
 energy', 'energy transfer'}

Matched key words from the dictionary and their
weights:
heat,2.6335476738
energy transfer,6.8079349437
energy,1.3698556348

Selected Key Word: energy transfer

Final Question:
Heat is a form of _____.
```

Fonte: (SHAH; SHAH; KURUP, 2017)

- Por fim, as demais palavras são elencadas como termos alternativos e de-

vem compor as outras respostas incorretas para a questão. São escolhidas sempre quatro alternativas, com uma única correta.

O trabalho alcançou bons resultados e conseguiu realizar as etapas de geração de questões e respostas sem intervenção humana e mostrando-se facilmente treinável em outra áreas de atuação. Os autores indicam como evolução a produção de respostas de uma linha, formando alternativas mais completas.

3.4 Considerações Finais

Este Capítulo buscou destacar o levantamento necessário para fundamentar os objetivos do projeto e a sua viabilidade. Foi possível observar o alinhamento da pesquisa com as técnicas de inteligência e as vantagens para os sistemas tutores que este desenvolvimento foi capaz de obter.

Destaca-se que o tratamento do conteúdo é uma necessidade da área observada pela revisão sistemática. Este trabalho contribui diretamente na melhoria do conteúdo e sua aplicação em sistema tutores inteligentes.

É importante destacar que a revisão sistemática abordada nesta literatura foi feita separadamente como etapa do projeto, e apenas alguns trechos de interesse foram selecionados para destaque. Métodos de revisão e seleção não foram abordados neste texto.

Neste capítulo se abordou os principais resultados necessários à fundamentação teórica do trabalho, destacando os tópicos centrais de atuação necessários a compreensão do trabalho.

Capítulo 4

Métodos e Técnicas

Neste Capítulo é apresentado um descritivo sobre o trabalho desenvolvido nesta tese, descrevendo o modelo de abordagem escolhido para alcançar seus objetivos. Além disso, é abordado o modelo de tratamento proposto para cada estilo e também a forma de viabilização da proposta.

4.1 Discussão da proposta

Antes de apresentar a metodologia de desenvolvimento, se reapresenta aqui a proposta efetiva de projeto, mostrando suas contribuições para a área de tutores inteligentes.

4.1.1 Definição do projeto

Para obter uma forma de tratamento que seja capaz de melhorar o tratamento do conteúdo em sistemas tutores inteligentes, a proposta deste trabalho busca construir estruturas de adaptação de um texto de entrada, produzindo variantes deste texto direcionadas a características de estilos de aprendizagem.

Observando a atividade central, o projeto abordado neste texto consiste na proposição e desenvolvimento de métodos, ou combinações de métodos de processamento de linguagem, para adaptação de texto. Destaca-se que este texto terá características e finalidades específicas, diferenciando-se da simples modificação de conteúdo, como abordado a seguir.

O método desenvolvido permitirá aplicação prática em ferramentas do tipo ITS, melhorando a capacidade de tratamento de conteúdo e trazendo evolução para o cenário atual.


Faz parte da proposta que este texto seja adaptado a partir de uma outra entrada de texto. Salienta-se que o texto referido deve ser entendido como um modelo completo para aprendizado, capaz de transmitir informações, como por exemplo

trechos de artigo ou notas sobre determinado assunto.

Com isso, propõe-se uma forma de criar inferência e variabilidade no conteúdo, produzindo um novo texto de forma controlada por assunto e direcionada aos estilos de aprendizagem.

De uma forma simples, o funcionamento básico descrito anteriormente pode ser visto na Figura 8. Pode-se partir, por exemplo, de um trecho de artigo abordando um tema específico, que seja a entrada fornecida pelo usuário. Com a metodologia aplicada, o objeto resultante será um nova abordagem do mesmo tema, porém construída a partir de tópicos centrais identificados pelo método e apresentada de acordo com o que é mais adequado para cada estilo de aprendizagem.

Figura 8: Visualização da Proposta



Fonte: Elaborada pelo autor

A variante proposta será produzida sempre com base no texto original de entrada, buscando a concentração nos tópicos e a fidelidade ao tema. O texto concentrado resultante cria variabilidade no conteúdo, o que gera outra abordagem para ensino. Esta versão gerada automaticamente atende as necessidades de introdução de conteúdo em sistemas tutores, pois a partir de uma entrada de interesse do usuário, é possível trazer uma nova forma de ensino.

É possível entender que a versão produzida é uma forma diferente de ensinar sobre o tema, contando ainda com direcionamento aos pontos importantes e as características de aprendizagem. Em sistemas tutores atuais isto seria possível por recomendação de outra fonte de conteúdo ou inserção manual na ferramenta.

A forma sintetizada também permite separação e ilustração dos pontos de concentração do tema, ideal para tornar a compreensão mais simples. É importante destacar que a metodologia construirá uma composição nova com a adaptação de texto, mas manterá a temática com as palavras chave.

Quanto aos estilos de aprendizagem, faz parte da proposta o estudo e a definição de um modelo de estilos de aprendizagem conhecido na literatura, desenvolvendo a proposta de adaptação a partir do direcionamento para seguir o método adequado para cada estilo de estudante.

Diante do cenário, a proposta busca trazer vantagens aos sistemas tutores, propondo um modelo que produza novas informações de acordo com os estilos de aprendizagem, sendo capaz de entregar um texto diferente da entrada recebida, mais direcionado e refinado no tema principal.

4.1.2 Metodologia de desenvolvimento

Para este trabalho foi proposta uma metodologia em fases de desenvolvimento, sendo as primeiras relacionadas a proposta efetiva do novo modelo de adaptação, e as seguintes marcadas por etapas de implementação de técnicas.

As fases de desenvolvimento podem ser definidas em:

- Levantamento das necessidades da área em sistemas tutores inteligentes e levantamento das técnicas de inteligência artificial que podem ser aplicadas.

Para esta etapa foi realizada uma revisão sistemática da literatura, criando fundamentação para a proposta e identificando o cenário atual para os tutores e as técnicas existentes de inteligência artificial e processamento de linguagem natural que podem ser aplicadas.

- Definição do modelo de estilos de aprendizagem para aplicação dos métodos e produção do conteúdo direcionado.

Para escolha do modelo, foram observadas na literatura as propostas de estilos de aprendizagem e suas características, adotando-se um modelo para a pré-definição de estilos deste trabalho.

- Estabelecimento/Proposta das relações entre os estilos de aprendizagem e a forma de abordagem funcional para cada tipo.

Esta etapa é marcada pela efetiva proposta do modelo, sendo definido qual tipo de adaptação de conteúdo deve ser feita para cada estilo, e como será feito o formato de exibição do novo conteúdo, marcando as etapas necessárias para a adaptação.

- Estabelecimento/Proposta das técnicas de inteligência artificial e processamento para texto que serão aplicadas para produzir a adaptação em cada estilo.

Após a definição do modelo, esta etapa define a escolha das técnicas para ser aplicada na produção dos novos tipos de texto.

- Implementação da adaptação proposta para processamento e verificação.

Esta etapa produz as implementações necessárias para testes práticos com produção efetiva dos novos conteúdos, incluindo testes de avaliação do conteúdo e testes de observação com voluntários.

O método desenvolvido permitirá aplicação prática para ensino, melhorando a capacidade de geração de conteúdo e contribuindo para a evolução do cenário atual.

O objetivo é que os textos adaptados sejam gerados a partir de uma outra entrada de texto. Este texto deve ser entendido como contendo informação suficiente para aprendizado, como por exemplo trechos de artigo ou notas de aula sobre determinado assunto.

4.1.3 Proposta da metodologia de adaptação de conteúdo

Esta seção se dedica a detalhar a proposta e seu funcionamento, abordando como é determinado o planejamento de processamento da entrada e quais os resultados esperados como saída.

Para determinar o modelo de funcionamento da proposta, foram definidos alguns parâmetros de acordo com a metodologia adotada e objetivos do projeto, sendo:

- Entrada a ser fornecida pelo usuário.

Para determinação da entrada que o modelo deve receber foram consideradas as necessidades dos sistemas tutores investigados. Devido a necessidade de diminuir a intervenção humana e aumentar a escalabilidade dos projetos, buscou-se reduzir ao máximo as entradas fornecidas pelo tutor/usuário do modelo.

Diante disso, o modelo foi proposto para receber apenas uma única entrada em texto, sendo este o conteúdo completo sobre o tema que será processado pelo modelo. Para a proposta, não há necessidade de formatação especial do texto ou de marcações específicas do tutor, sendo inserido, por exemplo, um capítulo de livro completo.

- Definição dos estilos de aprendizagem.

Para este modelo não é considerado como parte da proposta a determinação de qual grupo de estilos de aprendizagem o usuário pertence, sendo este um processo separado ao modelo que pode ser feito por avaliação em questionários.

Desta forma, o modelo produzirá o formato adequado para cada um dos quatro estilos, e estes serão disponibilizados para escolha do melhor formato.

- Processamento interno do modelo.

O processamento interno é a fase em que as técnicas serão aplicadas e os novos modelos adaptados serão produzidos. Para esta etapa, não deve ser necessária a participação do usuário para escolha de técnicas ou indicação de trechos.

Para a proposta, todo o processamento será feito sem o controle do usuário, o que torna a ferramenta altamente escalável e independente para funcionamento.

- Entrega dos novos modelos / Saídas.

A saída será produzida e identificada separadamente para cada estilo de aprendizagem. Para isto, cada estilo deve possuir uma proposta de apresentação individualizada de acordo com as necessidades.

Por exemplo, estilos mais adeptos a leitura e recepção de conteúdo devem receber mais textos e em formato diferenciado dos alunos mais ativos, que preferem experimentar. Desta forma, o modelo produzirá uma definição de estrutura para cada tipo de estilo, e esta será seguida para processamento e entrega do novo conteúdo.

As fases descritas anteriormente, podem ser exemplificadas pelo diagrama de caso de uso apresentada na Figura 9. O objetivo é ilustrar o processo com a mínima participação do usuário, tornando a ferramenta independente nas transformações.

Para a fase de processamento da entrada serão aplicadas as técnicas de processamento de linguagem natural, promovendo inferência e modificações no texto para a produção de versões. As técnicas devem ser capazes de sintetizar o texto, encontrar os termos chaves, o tema central, entre outras ações.


A fase de produção de saída por Estilo é a efetiva etapa de separação e produção da versão adaptada, incluindo produção disponibilização de questões e geração de texto.

4.2 Definições para tratamento dos estilos de aprendizagem

Esta seção aborda os detalhes que foram considerados sobre cada estilo para desenvolver a versão adaptada e para escolha de quais técnicas devem ser implementadas para construir o resultado.

A proposta avaliou as características de cada tipo do modelo de Kolb, propondo o melhor cenário para adaptação.

Figura 9: Caso de uso do modelo



Fonte: Elaborada pelo autor

4.2.1 Definição do modelo de aprendizagem

A pesquisa em estilos de aprendizagem destaca que a personalidade e características particulares de cada indivíduo é capaz de influenciar em sua capacidade de aprender e reter informação, considerando que as pessoas aprendem de forma diferente e têm um melhor desempenho quando o conteúdo é direcionado para estas preferências (CASSIDY, 2004).

Para este trabalho foi definida a aplicação do modelo de aprendizagem proposto por Kolb (KOLB, 1976b). O modelo, dividido em quatro estilos de aprendizagem, já é conhecido e estudado em várias áreas do conhecimento, obtendo resultados satisfatórios para direcionamento do ensino.

Cada estilo de aprendizagem fica em um quadrante e é cercado por dois itens do estágio de aprendizagem, este posicionamento indica a relação entre os modelos e o

aproveitamento de características em cada estilo.

Este compartilhamento de características colabora para a formação do modelo de adaptação de conteúdo, pois é possível aplicar combinações de técnicas para produzir os resultados seguindo a definição de cada item.

Desta forma, este trabalho escolheu os quatro estilos de aprendizagem definidos por Kolb para desenvolver o modelo de adaptação do conteúdo, de forma que a saída atenda as especificidades de cada tipo.

Nas próximas seções serão detalhadas as características definidas para o modelo de adaptação.

4.2.2 Versão escolhida do modelo de Kolb

O modelo de estilos utilizado para este trabalho foi revisado ao longo dos anos, originando novos estudos e mais divisões entre os estilos definidos (KOLB, 2007).

No entanto, este trabalho se concentrou na versão original com quatro determinações de estilo, tendo como motivação para escolha o fato da proposta ser mais simples para as delimitações da adaptação, tornando o processo mais claro e separável entre os estilos.

Por ser uma proposta inicial de adaptação, as versões evolutivas podem acrescentar alterações no modelo, sendo que a versão atualmente escolhida é suficiente para atender a proposta.

A Figura 10 ilustra este modelo de divisão em estágios no ciclo, e apoia a compreensão de como a interação pode ser considerada entre os elementos e o fluxo do aprendizado. Sendo:


- EA: Experimentação Ativa
- EC: Experiência Concreta
- OR: Observação Reflexiva
- CA: conceitualização Abstrata

4.2.3 Modelo Assimilador

Este estilo está situado entre as dimensões de Observação Reflexiva e Conceitualização Abstrata, sendo um tipo mais adepto a teoria e ao modelo lógico.

Assimiladores têm pouco interesse em pessoas, e preferem realizar uma abstração da teoria, de forma lógica e analítica. É o estilo menos interessado em realizar atividades práticas no aprendizado dos conceitos.

Figura 10: Ciclo de Estágios



Fonte: Elaborada pelo autor

Para os tutores, o ensino para este estilo deve ser administrado com oferecimento de conteúdo teórico de forma lógica e clara, de forma que o estudante consiga realizar inferências e reflexões do assunto a partir da exposição.

Com a avaliação do estilo e preparação para apresentar o conteúdo, este trabalho delimita como ponto de concentração para produzir conteúdo aos assimiladores como:

- Produção de textos teóricos mais direcionados ao assunto, fornecendo a teoria necessária ao estilo;
- Utilização de questões apenas como ferramenta de apoio ao ensino, não sendo o foco principal;
- Destaque de temas chave para assimilação.

4.2.4 Modelo Convergente

Estilo situado entre as dimensões de Conceitualização Abstrata e Experimentação Ativa, e assim como o modelo assimilador não é interessado em pessoas, possuindo um direcionamento mais prático.

Este modelo consegue encontrar soluções para questões e problemas práticos, e prefere aplicar a teoria para aprendizagem, de forma a testar os conhecimentos e validar o conteúdo.

Para os tutores, o ensinamento deste estilo deve ser feito de forma que permita simulações e trabalho com aplicações práticas, normalmente relacionado a tarefas técnicas.

Diante desta avaliação e para adaptação de estilos, este trabalho delimita como ponto de concentração para produzir conteúdo aos convergentes como:

- Produção de textos teóricos reduzidos, com informação concentrada no essencial para teoria;
- Destaque de temas chave para apoio a organização do conteúdo;
- Produção de questões como ferramenta chave para atividades práticas.

4.2.5 Modelo Acomodador

Estilo entre as dimensões de Experimentação Ativa e Experiência Concreta, se desenvolve melhor quando realiza atividades e se envolve em novas experiências. É, dos quatro estilos, aquele que mais assume risco, sendo também interessado em pessoas.

Para os tutores, é um estilo que prefere o aprendizado de forma ativa, sendo apenas guiado para a experimentação, sendo considerados como adaptáveis as situações.

Para a adaptação do estilo e considerando as características levantadas, este trabalho delimita como ponto de concentração para produzir conteúdo aos convergentes como:

- Produção de questões como ferramenta chave para atividades práticas;
- Redução do texto para versão concentrada de informações;
- Separação de termos para pesquisa;
- Disponibilização de técnica geradora para interação.

4.2.6 Modelo Divergente

O estilo divergente está entre as dimensões de Experiência concreta e Observação reflexiva, e tem um comportamento bem particular em comparação aos outros.

Os adeptos deste estilo são mais imaginativos e emocionais, preferindo ver os problemas concretos em mais de uma perspectiva. São interessados em aspectos culturais, e lidam bem com pessoas, sendo também criativos.

Para a adaptação do estilo e considerando as características levantadas, este trabalho delimita como ponto de concentração para produzir conteúdo aos convergentes como:

- Identificação prévia dos tópicos do texto para escolha por interesse;
- Sumarização por tópico;
- Disponibilização de técnica geradora para interação;
- Produção de questões.

4.2.7 Síntese dos métodos e formas de tratamento

Esta seção busca ilustrar o modelo esperado de comportamento para as adaptações propostas anteriormente. Desta forma, cada item representa, de forma ordenada por exibição do elemento, os resultados esperados para a visualização de cada estilo a partir das definições resultantes do modelo definido neste trabalho.

A listagem a seguir ilustra o modelo de exibição que o estilo assimilador terá após processamento do sistema.

- Texto teórico - Para atender as características de preferência por teoria e pensamento analítico, espera-se receber primeiramente um texto abordando o assunto. Este texto será uma versão minimamente resumida do padrão original, mantendo apenas a concentração nos temas principais, porém sem deixar de fornecer a temática esperada pelo estilo.
- Destaques - Para a função de destacar o tema, serão selecionadas frases chave do texto para apresentação. Para o estilo, é um direcionamento dos pontos para valorizar na reflexão sobre a teoria.
- Questões - As questões serão apresentadas sempre ao final, para que sejam executadas apenas como apoio e após toda a observação da teoria.

Para os convergentes, a listagem ilustra o modelo de exibição que o estilo terá após processamento do sistema.

- Destaques - Este estilo é adepto a receber menos teoria, neste caso os destaques são uma importante forma de síntese da temática do texto, permitindo que o usuário possa revisar a leitura se identificar alguma necessidade. Para isto, é extraído um tópico chave para apoio ao tema e frases chave para ilustrar a temática.

- Questões - As questões serão apresentadas após os tópicos, para que possa ser testado o conhecimento em um estilo de tentativa e erro.
- Texto teórico - Este estilo receberá apresentação de texto teórico, porém esta deve ser abordada em uma versão mais resumida que a anterior, refinando a temática. A presença deste estilo nas dimensões de realização de atividades, reduz a necessidade de uma abordagem fortemente teórica, permitindo uma redução do texto inicial e sua apresentação apenas ao final, como suporte.

O estilo Acomodador receberá um modelo de saída como pode ser visto na listagem a seguir.

- Texto teórico - O texto teórico deste estilo é apresentado em uma versão bem resumida neste ponto do modelo, sendo reduzido a um tamanho de tópico, apenas para introduzir a ideia geral.
- Questões - Este estilo receberá as questões ao início, de forma que já possa exercitar o assunto e se orientar identificando as suas próprias necessidades de conhecimento.
- Destaques - Para os acomodadores o destaque é feito por meio de indicações de Tag de Pesquisa. Dessa forma, o produto do sistema atua apenas como um direcionador, deixando-o livre para buscar o conteúdo centrado no tema.

Por fim, o estilo Divergente receberá o modelo produzido conforme a listagem.

- Destaques - Para este estilo, que busca interesse pessoal na temática, os destaques aparecem como uma seleção de palavras-chave que demarcam cada trecho de temática abordado no conteúdo. Assim, o estilo divergente pode buscar entre os temas o seu interesse.
- Texto teórico - O texto é apresentado em uma versão resumida e demarcada por cada palavra-chave que foi apresentada na seção anterior. Desta forma, o conteúdo trará uma síntese por tópicos.
- Texto teórico Complementar - Como complemento, são propostas conexões com técnicas generativas, para que estas possam retornar uma nova versão em texto de acordo com a temática de interesse identificada.
- Questões - Este estilo receberá as questões ao final, para que possa fundamentar o que foi aprendido.

4.3 Desenvolvimento e implementação da Proposta

Esta seção apresenta as estratégias de implementação avaliadas, elucidando aspectos abordados na construção da solução.

4.3.1 Aspectos técnicos

Este trabalho foi desenvolvido utilizando bibliotecas disponíveis na linguagem Python, principalmente Scikit Learn (KRAMER; KRAMER, 2016). A escolha desta estratégia esteve alinhada com a avaliação das necessidades do projeto e o desenvolvimento acelerado que as bibliotecas pré-implementadas representam como uma vantagem.

O desenvolvimento em Python permitiu atender aos requisitos do modelo, aplicando estruturas e funções já mapeadas dentro da tecnologia, apenas adaptadas para fins de estruturação da adaptação do conteúdo conforme proposto.

As bibliotecas foram aplicadas como uma composição de funções para criar a função de adaptação do conteúdo deste trabalho de acordo com a necessidade de cada estilo de aprendizagem. Nesse sentido, foram aplicadas técnicas que incluem:

- Extração de palavras-chave (FIROOZEH et al., 2020)
- Extração de Frases Chave (FIROOZEH et al., 2020)
- Sumarização (GAMBHIR; GUPTA, 2017)
- Funções de geração de texto (LI et al., 2022)

O objetivo principal deste estudo foi formular uma proposta de apresentação de conteúdo adequada a cada estilo de aprendizagem estudado nos modelos. As técnicas aplicadas possibilitaram a produção do modelo de apresentação proposto neste trabalho e facilitaram a avaliação dos resultados por meio de exemplos reais de textos processados.

Para este trabalho, diversas bibliotecas desempenharam papéis essenciais em tarefas de processamento de linguagem natural. Para a sumarização, utilizou-se a combinação de técnicas do método TF-IDF (Term Frequency-Inverse Document Frequency) da biblioteca *TfidfVectorizer*, ajustando o nível mínimo de sumarização para 0.65 e máximo para 0.90.

Para a extração de palavras e frases chave, foram utilizadas as combinações de funções *PorterStemmer*, *sent_tokenize*, *word_tokenize* da própria biblioteca NLTK (Natural Language Toolkit), para tokenização e redução de palavras.

Por fim, foi utilizada a integração com GPT-2 em sua versão *gpt-2-simple* com 774 milhões de parâmetros e com implementação via chamada da biblioteca *trans-*

formers. As sessões abertas estavam configuradas para geração em temperatura 0.7, e tamanho 100, recebendo como entrada de prompt a tag de Pesquisa gerada por meio da extração de tópicos.

4.3.2 Processamento de texto e adaptação de conteúdo

Para a construção do modelo com conteúdo adaptado espera-se uma entrada composta por um texto completo sobre o assunto a ser abordado. Esse texto de entrada pode ser extraído de artigos, livros, não havendo necessidade de pré-formatação por parte do autor ou indicação de tema central; apenas um texto simples precisa ser fornecido.

A partir do texto de entrada, a função principal desenvolvida neste trabalho coordena a adaptação do conteúdo aplicando funções de pré-processamento de processamento de linguagem natural, organizando a saída de acordo com o resultado esperado de cada estilo de aprendizagem.

A partir de uma única entrada, são produzidas quatro versões adaptadas segundo os modelos de aprendizagem de Kolb, com exceção das questões, que são geradas a partir de metodologia desenvolvida em outro projeto. O processo de adaptação é totalmente automatizado e não envolve qualquer participação do usuário.

Nesta versão inicial desenvolvida, o modelo é destinado ao professor, que insere o conteúdo a ser trabalhado e recebe as versões adaptadas para seus alunos. Por esse motivo, a versão desenvolvida oferece diretamente as quatro opções para um único usuário.

4.4 Considerações finais

Nas seções anteriores foram apresentadas as adaptações propostas, construídas com base nas observações das características de cada estilo. Cada proposta será decomposta em técnicas para criação automatizada de cada item.

As técnicas permitiram que o conteúdo adaptado fosse automaticamente produzido, sem a necessidade de interferência humana no processo.

Foram aplicadas técnicas de processamento de linguagem natural e métodos de inteligência artificial para a produção, sendo que cada técnica escolhida é determinada para produção de um dos resultados esperados da adaptação.

Capítulo 5

Resultados

As avaliações iniciais realizadas sobre o desempenho dos métodos observaram as características dos textos produzidos. Foram avaliados os níveis de redução alcançados na produção do texto final, bem como a qualidade do texto em termos de informações preservadas.

Para esta etapa, buscou-se uma avaliação holística do conteúdo produzido, observando a qualidade dos resultados para cada métrica e a composição dos resultados como um texto personalizado construído como um único resultado em linguagem natural.

As seções seguintes abordaram alguns pontos destacados com base na observação dos resultados.

5.1 Sumarização de texto

A sumarização do texto é uma etapa crucial nesta proposta, em que o nível de sumarização aplicado é controlado com base na finalidade e tamanho do texto de entrada, garantindo que o usuário final receba um resumo das informações mais importantes de acordo com as expectativas do seu estilo de aprendizagem .

Para assimiladores e convergentes, mais propensos à recepção e leitura passiva de conteúdos, a sumarização resulta numa redução de cerca de 50% a 65% nos níveis mínimos das palavras originais, garantindo uma apresentação do conteúdo principal.

A escolha da sumarização extrativa garante que o texto produzido não se desvie do conteúdo de entrada, evitando saídas inesperadas para o tutor. Além disso, as pontuações das frases são calculadas para evitar perda de significado, principalmente considerando sua finalidade educacional.

Em um texto teste foi realizada uma sumarização que reteve 53% da informação original. O resumo resultante foi claro e conciso, mantendo uma duração de leitura adequada aos estilos de aprendizagem mais inclinados à leitura durante as sessões

de estudo.

Para acomodadores e divergentes, as reduções apresentadas podem chegar a aproximadamente 90%, resultando apenas em um texto de conteúdo norteador, o que é suficiente para esses personagens, preferem o estudo com postura ativa e não utilizam muitos materiais didáticos. A título de exemplo, o texto apresentado na caixa a seguir foi extraído da Wikipedia e tem quase 1.300 palavras (um artigo de aproximadamente 3 páginas). Foi utilizado como entrada para gerar um texto visando acomodadores.

Para exemplificar esse processo, será mostrado um tópico gerado especificamente para acomodadores a partir deste grande texto sobre algoritmos genéticos. Ele foi gerado automaticamente a partir do texto original e é possível observar que resumir mantém apenas um assunto importante.

A geração original foi a partir de texto em língua inglesa que é o foco principal deste trabalho pela abrangência do idioma. A tradução é apresentada em seguida para ilustrar esse comportamento.

Tree-like representations are explored in genetic programming and graph-form representations are explored in evolutionary programming; a mix of both linear chromosomes and trees is explored in gene expression programming. Certain selection methods rate the fitness of each solution and preferentially select the best solutions. The fitness function is defined over the genetic representation and measures the quality of the represented solution. The fitness function is always problem dependent. Opinion is divided over the importance of crossover versus mutation. There are many references in Fogel (2006) that support the importance of mutation-based search. Termination This generational process is repeated until a termination condition has been reached.
(Texto originalmente gerado pelo modelo)

Representações semelhantes a árvores são exploradas na programação genética e representações em forma de gráfico são exploradas na programação evolutiva; uma mistura de cromossomos lineares e árvores é explorada na programação de expressão gênica. Certos métodos de seleção avaliam a adequação de cada solução e selecionam preferencialmente as melhores soluções. A função de aptidão é definida sobre a representação genética e mede a qualidade da solução representada. A função de aptidão sempre depende do problema. As opiniões estão divididas sobre a importância do cruzamento versus mutação. Existem muitas referências em Fogel (2006) que apoiam a importância da pesquisa baseada em mutações. Terminação Este processo geracional é repetido até

que uma condição de término seja alcançada.
(Tradução nossa)

Como esperado, o processo resumiu a parte central do texto e transformou-a em uma apresentação concisa em formato de tópico, atendendo diretamente às expectativas desse estilo de aprendizagem.

5.2 Métodos extrativos

Foram aplicadas técnicas de extração no contexto de palavras-chave e tópicos de cada texto, em que um tópico corresponde ao tamanho de uma frase (frase-chave).

A disposição desses itens ao longo dos textos permitiu a criação de um suporte norteador do conteúdo, facilitando a identificação dos principais assuntos abordados no texto, e isso foi aplicado a todos os estilos.

Além disso, a extração de frases-chave serviu de pano de fundo para diversos métodos de manter a sumarização focada no tema central.

Por exemplo, considerando o texto fonte que acabamos de apresentar, foram definidos os seguintes tópicos principais, entre parênteses, a palavra-chave central:

- Tree-like representations are explored in genetic programming and graph-form representations are explored in evolutionary programming - (Keyword: evolutionary)

Representações semelhantes a árvores são exploradas na programação genética e representações em forma de grafo são exploradas na programação evolutiva - Palavra-chave: evolucionário (Tradução nossa)

- In computer science and operations research, a genetic algorithm (GA) is a metaheuristic inspired by the process of natural selection that belongs to the larger class of evolutionary algorithms (EA) - (Keyword: genetic)

Em ciência da computação e pesquisa operacional, um algoritmo genético (GA) é uma metaheurística inspirada no processo de seleção natural que pertence à classe maior de algoritmos evolutivos (EA) - Palavra-chave: genética (Tradução nossa)

- Genetic algorithms are commonly used to generate high-quality solutions to optimization and search problems by relying on biologically inspired operators such as mutation, crossover and selection - (Keyword: algorithms)

Algoritmos genéticos são comumente usados para gerar soluções de alta qualidade para problemas de otimização e pesquisa, contando com operadores bio-

logicamente inspirados, como mutação, cruzamento e seleção - Palavra-chave: algoritmos (Tradução nossa)

5.3 Métodos generativos

Para efeito deste trabalho, o método generativo foi aplicado apenas aos modelos acomodador e divergente, que apresentam interesse em conteúdo além do esperado dentro das variações da entrada original fornecida.

Neste estudo, o GPT-2 ((RADFORD et al., 2019)) foi empregado como auxiliar de pesquisa, gerando conteúdo a partir de um tema previamente inserido pelo usuário. Essa estratégia foi escolhida para manter a capacidade generativa controlada e alinhada aos interesses do tutor que utiliza a ferramenta.

O conteúdo produzido está incluído na versão final dos textos apresentados a cada modelo e serve para satisfazer a necessidade de observar outra fonte de informação, característica destes estilos de aprendizagem.

Em versões futuras, os avanços com integrações permitidas dentro do GPT-3 (BROWN et al., 2020) podem ser explorados, ou GPT-4 (ACHIAM et al., 2023). Porém, para este efeito, a Versão 2 já reúne as capacidades de processamento e tratamento de texto exigidas.

5.4 Testes de observação

Embora este trabalho não se concentre na observação do comportamento de usabilidade, mas sim na construção de um modelo adaptativo baseado nos métodos descritos nas seções anteriores, foram realizados testes de observação de usuários referentes aos textos produzidos.


Os texto utilizado na avaliação e as quatro apresentações adaptadas do tema estão inseridas no Apêndice B. As questões apresentadas para avaliação do formulário estão no Apêndice C.

A participação foi voluntária e envolveu 39 participantes. O teste forneceu aos usuários informações sobre seu estilo de aprendizagem com base em um questionário simples e de acordo com a estratégia de Kolb. Os participantes foram inicialmente classificados a partir de suas respostas ao questionário proposto por Kolb, sendo que sua composição de estilos foi a seguinte (Figura 11):

- 43,6% Assimiladores;
- 33,3% Convergentes;
- 15,4% Divergentes;

- 7,7% Acomodadores.

Figura 11: Resultados obtidos para categorização dos participantes em estilos



Fonte: Elaborada pelo autor

A taxa de concordância pessoal com o estilo resultante foi de 92,3%. Entre os que discordaram, a opinião pessoal foi apenas de que poderiam se enquadrar em mais de um tipo, o que foi considerado adequado para as provas.

Com conhecimento do seu próprio estilo, os participantes receberam primeiro o texto adaptado e depois o texto completo (original) para comparação. Após o processo, foram feitas algumas perguntas sobre sua experiência.

O objetivo das observações foi compreender o nível de conforto dos participantes com o texto adaptado e avaliar os benefícios percebidos de seu uso. Para este teste foi escolhido um artigo sobre o funcionamento de algoritmos genéticos, e apenas 2,6% dos participantes afirmaram ter conhecimento prévio sobre o assunto.

As respostas foram coletadas usando uma escala Likert (LIKERT, 1932) de concordância. Os resultados são mostrados e discutidos a seguir.

A Tabela 6 ilustra os resultados das duas primeiras afirmações quanto a preferência em relação a temática abordada. Estes questionamentos têm o objetivo de entender o conhecimento prévio do aluno no tema abordado e também seu nível de interesse em receber informações neste assunto, o que influencia quanto a receptividade.

Tabela 6: Avaliação quanto ao conteúdo que será utilizado no teste

Afirmação	Concordância	Neutro	Discordância
Eu já conhecia o conteúdo abordado.	43,6%	10,3%	23,1%
Tenho interesse no tema abordado.	58,9%	33,4%	7,7%

Os resultados quanto a preferência mostraram um cenário satisfatório para a pesquisa, sendo possível elencar que:

- Menos da metade dos participantes afirmaram ter conhecimento prévio no assunto, o que indica que estão recebendo primeiro contato com um material de ensino nesta temática, o que permitirá avaliar a técnica reduzindo a probabilidade de viés por conhecimento anterior;
- Menos de 10% afirmaram não ter interesse no assunto estudado, sendo que a maioria restante demonstrou interesse e isso permite um maior interesse nos resultados.

Um ponto importante desta avaliação foi o questionamento quanto ao sentimento em relação ao modelo recebido, o que reflete a opinião do participante quanto a experiência de aprendizagem com o material já adaptado pela metodologia. A Tabela 7 ilustra esses resultados.

Tabela 7: Avaliação de sentimento em relação ao modelo recebido

Afirmção	Concordância	Neutro	Discordância
Me senti confortável com o formato de apresentação do conteúdo	82,0%	2,6%	15,4%
Me senti confortável com a ordem em que o conteúdo foi apresentado	92,3%	2,6%	5,1%
Me senti confortável com os tipos de apresentação escolhidos	84,6%	5,1%	10,3%
O modelo apresentado atendeu às minhas preferências de aprendizagem.	82,1%	10,3%	7,7%

Dentro dos resultados observados é possível destacar que:

- Mais de 80% dos participantes se sentiram confortáveis com o formato de apresentação do conteúdo. Este resultados indica que a metodologia proposta conseguiu formatar a apresentação do conteúdo, automaticamente, de maneira adequada a preferência dos estilos, atendendo as necessidades;
- Mais de 90% declararam estar confortáveis com a ordem de apresentação e mais de 80% estavam confortáveis com os tipos de apresentação. Cada tipo de apresentação e ordenação foi diretamente proposto na estrutura da metodologia a partir das indicações do modelo de Kolb no ciclo de aprendizagem, sendo que estes resultados mostram uma taxa de aceitação alta na escolha da adaptação;
- Além disso. mais de 80% concordaram que a apresentação atendeu as preferências de aprendizagem. Este resultado demonstra diretamente que a adaptação automática conseguiu refletir o preparo de material adequado as expectativas de cada estudante. Este resultado impacta diretamente na vantagem de

escalabilidade desta metodologia, sendo possível automatizar a produção de conteúdo diversificado.

Os resultados mostraram que a maioria dos participantes se sentiu confortável com a versão produzida automaticamente e que o modelo proposto atendeu às suas expectativas em relação às suas preferências de aprendizagem. Esta avaliação indica que a experiência pessoal foi positiva quanto à recepção do conteúdo elaborado.

Outras questões foram sobre comparar perspectivas sobre textos adaptados, como demonstra a 8.

Tabela 8: Avaliação da experiência em relação ao modelo recebido

Afirmação	Concordância	Neutro	Discordância
Quando estudo sozinho, gosto de adotar um formato semelhante ao modelo que me foi dado	89.8%	7.7%	2.6%
Considero o texto apresentado como norteador do estudo do tema	87.2%	12.8%	0%
Considero o texto apresentado um complemento e/ou fonte extra para o estudo do tema	74,3%	17,9%	7,7%
O texto apresentado foi claro	92,3%	5,1%	2,6%
Os tópicos apresentados resumiram bem os pontos principais e pontos de atenção.	92,3%	2,6%	5,1%
As questões foram uma prática interessante para o aprendizado.	84,6%	10,3%	5,2%

Diante dos resultados é possível destacar que:

- Mais de 90% dos participantes concordaram sobre a semelhança do padrão de estudo apresentado quanto ao padrão adotado ao estudar sozinho, e também quanto considerar o texto um norteador do tema. Estes resultados indicam que a metodologia conseguiu apresentar as versões adaptadas funcionando como um tutor de apoio, direcionando o estudo dos conteúdos dentro das preferências de cada estudante.
- Além disso, mais de 70% consideraram que os conteúdos funcionavam como uma fonte extra para o estudo. este resultado impacta diretamente na função de apoio ao tutor humano que esta proposta tem no seu objetivo, mostrando que um tutor pode produzir materiais que apoiem os alunos, complementando o que foi visto em aula.
- Mais de 90% consideraram o texto claro, o que é fundamental visto que é uma versão totalmente automatizada que precisa manter a fidelidade com a correção, e consideraram também que os tópicos resumiram bem os pontos,

o que também era um objetivo a ser alcançado dentro da automatização na produção.


- Por fim, mais de 80% indicaram que as questões adotadas também foram uma boa estratégia para o aprendizado, mostrando ser uma escolha acertada da metodologia.

O ponto mais significativo desses resultados diz respeito à taxa de concordância de quase 90% quanto à similaridade do formato ao estudar sozinho, indicando que o modelo replicou com sucesso a preferência de cada indivíduo, entregando um material estreitamente alinhado com a real necessidade dos alunos.

Continuando a avaliar os resultados referentes ao texto produzido, 92,3% consideraram o texto claro e constataram que os tópicos apresentados resumiram bem os principais pontos do texto original.

A Figura 12 ilustra resultados sobre questões de tópicos. As cores azul e vermelho estão respectivamente de acordo total e parcialmente.

Figura 12: Resultados obtidos para afirmação sobre a capacidade do modelo de resumir pontos chave e temas centrais do texto principal



Fonte: Elaborada pelo autor

O objetivo deste teste foi apenas observar uma pequena amostra de reações para validação holística do conteúdo apresentado, e os resultados foram satisfatórios.

5.5 Discussão sobre redes generativas no cenário dos resultados

Um ponto de discussão que precisa ser abordado é a interseção dos objetivos deste trabalho com a evolução das redes generativas e suas capacidades de processamento de linguagem natural para diversos fins. Contudo, é importante destacar que os

objetivos diferem quanto às finalidades pretendidas dos tratamentos e que ambos são complementares e não exclusivos.

Certamente, as redes generativas têm a capacidade de combinar informações e organizá-las de forma clara para transmitir uma ideia. Além disso, é possível citar outras técnicas de IA generativa que são um case de sucesso:

- LLama (TOUVRON et al., 2023);
- Sabiá - 2 (PIRES et al., 2023)
- Bard (GOOGLE, 2023)

As redes generativas estão em constante melhoria e serão cada vez mais parte da vida quotidiana como ferramenta de apoio. Porém, a capacidade generativa ainda pode provocar alterações no texto que afetem o conteúdo da informação a ser veiculada, alterando o conteúdo para uma versão que pode não ser a mais precisa.

O objetivo deste trabalho é extrair informações de um texto já revisado e permitir a criação de versões adaptadas dentro de padrões especificados para cada modelo de aprendizagem. Dessa forma, um tutor terá diversas versões de um texto para diferentes tipos de alunos, mas há controle sobre o conteúdo.

Especialmente em casos educacionais, a informação transmitida com precisão é importante para atingir o objetivo de ensino sobre um tema escolhido.

Nesse sentido, as redes generativas complementam esta proposta e podem ser utilizadas em contextos específicos como conteúdo extra gerado para alunos de aprendizagem ativa, que gostam de contato com pesquisas e outras fontes.

As redes generativas aplicam-se a discussões em grupo ou troca de informações entre alunos, em situações que permitem abertura a outros pontos de vista e trazem benefícios à aprendizagem.

Estes modelos em suas versões atuais e em seus aprimoramentos futuros são capazes de compreender as recomendações definidas por Kolb na proposição do modelo, dentro do contexto geral das características. Por exemplo, pode-se observar esta saída:

“For assimilator learning styles, understanding genetic algorithms involves grasping the analogy between genetic operations and their biological counterparts. By visualizing how genetic algorithms iteratively refine solutions through simulated evolution, assimilators can appreciate the logical progression and systematic approach underlying this optimization technique.” (Texto gerado pelo chatGPT 3.5)

“Para estilos de aprendizagem assimiladores, compreender os algoritmos genéticos envolve compreender a analogia entre as operações

genéticas e suas contrapartes biológicas. Ao visualizar como os algoritmos genéticos refinam iterativamente as soluções por meio da evolução simulada, os assimiladores podem apreciar a progressão lógica e a abordagem sistemática subjacente a esta técnica de otimização.” (Tradução Nossa)

No entanto, é importante observar que as ferramentas são capazes de compreender o contexto dos modelos de acordo com sua definição teórica. Porém, a proposta deste trabalho foi criar um modelo ideal e padronizado para cada estilo de aprendizagem, dentro do que melhor se adequa ao conteúdo que será personalizado em ambiente controlado. O modelo apresenta mais variabilidade do que apenas texto, utilizando propostas de perguntas, palavras-chave e observação de tópicos.

O modelo de trabalho proposto tem a ganhar significativamente com os avanços nas redes generativas, utilizando-as como ferramentas complementares e simulando a troca de informações semelhante à humana, atuando de forma conjunto e não excludente dentro do cenário de sistemas tutores.

5.6 Considerações finais

Esta seção trouxe os resultados e observações do modelo em funcionamento. Foi importante observar os resultados positivos encontrados e os objetivos alcançados dentro do contexto.

Também nesta seção, foi possível observar a comparação com o contexto de redes generativas e a sua função nesse cenário.

Capítulo 6

Conclusões

O trabalho desenvolvido foi proposto com base em estudos do modelo Kolb e nas necessidades de cada estilo de aprendizagem. A proposta trouxe as particularidades de cada tipo para um formato que pudesse ser reproduzido automaticamente por algoritmos de linguagem natural.

Obter um modelo padronizado para cada tipo e identificar a equivalência com a proposta de Kolb foi o principal diferencial. A implementação comprovou ainda mais a viabilidade do que estava sendo proposto dentro do contexto.

Além disso, foi possível manter o conteúdo adaptado dentro de uma estrutura controlada, permitindo que ele fosse utilizado por um tutor sem a preocupação de que a variabilidade comprometesse o conteúdo.

Os testes de avaliação do conteúdo mostraram que a geração foi de qualidade satisfatória e que o atendimento aos requisitos foi viável. Os testes de observação também demonstraram o potencial caso de utilização da aplicação num grupo de alunos, inculcando mais confiança nos resultados produzidos.

O modelo produzido neste trabalho cumpriu seu propósito e conseguiu trazer um novo cenário de adaptação de conteúdo, ao mesmo tempo que teve o potencial de aprimorar sua capacidade com tecnologias disruptivas, como modelos generativos.

Este trabalho apresenta uma proposta para atender às necessidades identificadas em sistemas tutores inteligentes, melhorando a escalabilidade e a capacidade de atendimento da solução.

A criação deste modelo proposto distingue-se pela automatização do processo, de forma a garantir a produção de conteúdos adaptados, num novo formato, a partir de uma única entrada.

Além disso, a formatação por estilo atende a uma necessidade do usuário, que recebe as informações em um formato conveniente para uso.

A proposta se destaca por atender uma demanda existente na área e propor a solução em um novo formato. Os resultados demonstraram o alcance dos objetivos.

6.1 Trabalhos futuros

A proposta desenvolvida neste trabalho é a primeira versão de aplicação do modelo de acordo com os estilos de aprendizagem de Kolb, e para desenvolvimentos futuros podem ser feitas as seguintes sugestões:

- Expandir a definição do modelo de Kolb:

Este trabalho aplicou a primeira versão do modelo de Kolb, utilizando os quatro estilos de aprendizagem definidos: convergente, divergente, assimilador e acomodador. Cada um desses estilos descreve como os indivíduos preferem aprender e processar informações, baseando-se em um ciclo formado pelos quadrantes de experiência concreta, observação reflexiva, conceitualização abstrata e experimentação ativa.

O modelo de Kolb tem sido amplamente utilizado em diversas áreas educacionais e profissionais para melhor compreender e adaptar métodos de ensino e treinamento às necessidades dos alunos, sendo escolhido para este trabalho como um modelo viável para aplicação da metodologia proposta e que permitiria uma interpretação mais simples do processo.

Para trabalhos futuros, sugere-se uma expansão para a versão estendida do modelo de estilos de aprendizagem de Kolb. Esta versão revisada introduz mais dimensões ao processo de aprendizagem, reconhecendo que as preferências de aprendizagem podem variar dentro dos mesmos estilos inicialmente definidos.

Implementar a versão estendida do modelo de Kolb em trabalhos futuros permitirá uma compreensão mais profunda e precisa das diferenças individuais nos estilos de aprendizagem. Isso pode resultar em estratégias de ensino mais eficazes, adaptadas às necessidades específicas dos alunos, e em ambientes de aprendizagem mais inclusivos e motivadores.

- Potencializar o envolvimento das redes generativas como ferramenta complementar a este trabalho:

Este trabalho explorou a aplicação de ferramentas de redes generativas de forma inicial, como um método de suporte a uma das frentes da metodologia proposta, sendo reconhecido o potencial dessas tecnologias para enriquecer os processos de aprendizado e desenvolvimento.

Com a evolução dos modelos de LLM (Large Language Modelo), há um interesse crescente de como essas ferramentas podem oferecer suporte avançado em diversas áreas, incluindo a criação de conteúdos educacionais personalizados e interação com o usuário.

Para trabalhos futuros, sugere-se potencializar o envolvimento das redes generativas aproveitando as capacidades expandidas dos novos modelos de LLM. Essa evolução permite a criação de métodos precisos, que podem ser utilizados para desenvolver materiais educativos, adaptados e responsivos. Também é possível citar a inclusão de sumários abstrativos.

A integração de redes generativas avançadas, pode trazer vantagens significativas no campo educacional, ampliando as possibilidades de personalização e inovação. Ao implementar essas tecnologias, futuros trabalhos podem explorar novos métodos de engajamento dos alunos, criar ambientes de aprendizado mais interativos, e desenvolver ferramentas que facilitem a aprendizagem.

- Aplicação da ferramenta desenvolvida em disciplina real:

Este trabalho concentrou-se no desenvolvimento de uma metodologia inovadora destinada a aprimorar o processo educacional, e também desenvolveu a ferramenta com as técnicas necessárias para alcançar o resultado. Este trabalho já apresentou um conjunto de testes com voluntários, no entanto, há uma necessidade de validar sua atuação em contextos educacionais reais. Aplicar essas técnicas em uma disciplina real permitirá uma avaliação mais precisa de seu impacto no desempenho, na experiência dos alunos e na experiência do tutor.

Para trabalhos futuros, sugere-se a implementação desta ferramenta em uma disciplina real, observando o desempenho dos alunos ao longo do período. Esse experimento pode incluir a coleta de dados quantitativos e qualitativos, como notas, feedback dos alunos e observações dos professores. Além disso, também é possível fazer experimentos com os alunos em pares, comparando os resultados de desempenho com a utilização de materiais personalizados.

Medir esses indicadores permitirá uma compreensão mais profunda de como a ferramenta influencia o aprendizado, identifica pontos fortes e áreas que precisam ser melhoradas, além de avaliar a sua aceitação pelos usuários.

A aplicação em um ambiente educacional real também fornecerá visões valiosas sobre a adaptabilidade e escalabilidade da ferramenta. Esse processo de avaliação e melhoria contínua contribuirá para a criação de um recurso educacional robusto, capaz de potencializar o aprendizado e o desempenho dos alunos de maneira significativa e sustentável.

6.2 Publicações do trabalho

Até a presente data, os resultados deste trabalho foram publicados:

- Peronaglio, F. F., Manacero, A., Baldassin, A. J., Dos Santos, M. S., Lobato, R. S., Spolon, R., & Cavenaghi, M. A. (2023). Adaptação automática de conteúdo aplicada em ambiente interativo de aprendizagem individualizada. *Revista Brasileira de Informática na Educação*, 31, 255-270. (Qualis A4)
- Santi, M., Manacero, A., Peronaglio, F. F., Lobato, R. S., Spolon, R., & Cavenaghi, M. A. (2022, June). Training Transformers for Question Generation Task in Intelligent Tutoring Systems. In *2022 17th Iberian Conference on Information Systems and Technologies (CISTI)* (pp. 1-6). Ieee. (Qualis A4)

Também estão em avaliação as submissões realizadas:

- Transactions on Learning Technologies (A1)
- Simpósio Brasileiro de Informática na Educação (A3)

6.3 Ética em pesquisa

O trabalho foi validado por testes realizados com humanos voluntários (estudantes de ciência da computação) e foi autorizado pelo comitê de ética em pesquisa, sob número de processo 67815522.0.0000.5466.

Referências

- ACHIAM, J. et al. Gpt-4 technical report. *arXiv preprint arXiv:2303.08774*, 2023.
- ALDAY, R. B. Bayesian networks in intelligent tutoring systems as an assessment of student performance using student modeling. In: *Proceedings of the 2018 2nd International Conference on Algorithms, Computing and Systems*. [S.l.: s.n.], 2018. p. 119–122.
- AROMATARIS, E.; PEARSON, A. The systematic review: an overview. *AJN The American Journal of Nursing*, LWW, v. 114, n. 3, p. 53–58, 2014.
- BEGEL, A.; GARCIA, D. D.; WOLFMAN, S. A. Kinesthetic learning in the classroom. *ACM SIGCSE Bulletin*, ACM New York, NY, USA, v. 36, n. 1, p. 183–184, 2004.
- BLOOM, B. et al. *Taxonomy of educational objectives: Cognitive domain*. [S.l.]: Longmans, 1956.
- BORHADE, R. R. et al. Smart education system to improve the learning system with cbr based recommendation system using iot. 2023.
- BROWN, T. B. et al. Language models are few-shot learners. *arXiv preprint arXiv:2005.14165*, 2020.
- BRUNER, J. *Toward a theory of instruction*. [S.l.]: Harvard University Press, 1974.
- CASSIDY, S. Learning styles: An overview of theories, models, and measures. *Educational psychology*, Taylor & Francis, v. 24, n. 4, p. 419–444, 2004.
- COFFIELD, F. et al. Learning styles and pedagogy in post-16 learning: A systematic and critical review. 2004.
- CORBETT, A. T.; KOEDINGER, K. R.; ANDERSON, J. R. Intelligent tutoring systems. In: *Handbook of human-computer interaction*. [S.l.]: Elsevier, 1997. p. 849–874.
- CORBI, A.; BURGOS, D. Implementation of the recommendation model line in cognitive and visual interactive tutors from pslc. *IEEE Latin America Transactions*, IEEE, v. 13, n. 2, p. 516–522, 2015.
- DAI, K.; QIU, Y.; ZHANG, R. The construction of learning diagnosis and resources recommendation system based on knowledge graph. In: IEEE. *2021 IEEE International Conference on Progress in Informatics and Computing (PIC)*. [S.l.], 2021. p. 253–259.

- DAOMIN, X.; MINGCHUI, D. Appropriate learning resource recommendation in intelligent web-based educational system. In: IEEE. *2013 Fourth International Conference on Intelligent Systems Design and Engineering Applications*. [S.l.], 2013. p. 169–173.
- DUFF, A.; DUFFY, T. Psychometric properties of honey & mumford's learning styles questionnaire (lsq). *Personality and individual differences*, Elsevier, v. 33, n. 1, p. 147–163, 2002.
- FELDER, R. M. Learning and teaching styles in engineering education. THE NATIONAL ACADEMIES, 2002.
- FIROOZEH, N. et al. Keyword extraction: Issues and methods. *Natural Language Engineering*, Cambridge University Press, v. 26, n. 3, p. 259–291, 2020.
- FLEMING, N. D.; MILLS, C. Not another inventory, rather a catalyst for reflection. *To improve the academy*, Wiley Online Library, v. 11, n. 1, p. 137–155, 1992.
- GAMBHIR, M.; GUPTA, V. Recent automatic text summarization techniques: a survey. *Artificial Intelligence Review*, Springer, v. 47, p. 1–66, 2017.
- GARDNER, H. E. *Frames of mind: The theory of multiple intelligences*. [S.l.]: Basic books, 1983.
- GOOGLE. *Bard: Large Language Model by Google*. 2023. Accessed: 2024-08-10. Disponível em: <https://bard.google.com>.
- HAN, J. et al. Intelligent tutoring system trends 2006-2018: A literature review. In: IEEE. *2019 Eighth International Conference on Educational Innovation through Technology (EITT)*. [S.l.], 2019. p. 153–159.
- HSU, C.-K.; HWANG, G.-J.; CHANG, C.-K. Development of a reading material recommendation system based on a knowledge engineering approach. *Computers & Education*, Elsevier, v. 55, n. 1, p. 76–83, 2010.
- HUO, Y.; XIAO, J.; NI, L. M. Towards personalized learning through class contextual factors-based exercise recommendation. In: IEEE. *2018 IEEE 24th International Conference on Parallel and Distributed Systems (ICPADS)*. [S.l.], 2018. p. 85–92.
- IDKHAN, A. M.; IDRIS, M. M. Dimensions of students learning styles at the university with the kolb learning model. *International Journal of Environment, Engineering & Education*, v. 3, n. 2, p. 75–82, 2021.
- JANJANAM, P.; REDDY, C. P. Text summarization: An essential study. In: IEEE. *2019 International Conference on Computational Intelligence in Data Science (IC-CIDS)*. [S.l.], 2019. p. 1–6.
- JOYCE, B. R.; HODGES, R. E. Instructional flexibility training. *Journal of Teacher Education*, Sage Publications Sage CA: Thousand Oaks, CA, v. 17, n. 4, p. 409–416, 1966.

- JUGO, I.; KOVAČIĆ, B.; SLAVUJ, V. Using data mining for learning path recommendation and visualization in an intelligent tutoring system. In: IEEE. *2014 37th international convention on Information and communication technology, electronics and microelectronics (MIPRO)*. [S.l.], 2014. p. 924–928.
- JUNG, C. G. *The development of personality*. [S.l.]: New York : Pantheon Books, 1954.
- KAYALAR, F.; KAYALAR, F. The effects of auditory learning strategy on learning skills of language learners (students' views). *IOSR Journal Of Humanities And Social Science (IOSR-JHSS)*, v. 22, n. 10, p. 04–10, 2017.
- KHODEIR, N. et al. Bayesian based adaptive question generation technique. *Journal of Electrical Systems and Information Technology*, Elsevier, v. 1, n. 1, p. 10–16, 2014.
- KLAŠNJA-MILIĆEVIĆ, A.; VESIN, B.; IVANOVIĆ, M. Social tagging strategy for enhancing e-learning experience. *Computers & Education*, Elsevier, v. 118, p. 166–181, 2018.
- KLAŠNJA-MILICEVIC, A. et al. Personalisation of programming tutoring system using tag-based recommender systems. In: IEEE. *2012 IEEE 12th International Conference on Advanced Learning Technologies*. [S.l.], 2012. p. 666–667.
- KOLB, D. A. *Learning style inventory technical manual*. [S.l.]: McBer Boston, 1976.
- KOLB, D. A. Management and the learning process. *California management review*, SAGE Publications Sage CA: Los Angeles, CA, v. 18, n. 3, p. 21–31, 1976.
- KOLB, D. A. *Learning-style inventory: Self-scoring inventory and interpretation booklet*. [S.l.]: TRG Hay/McBer, 1985.
- KOLB, D. A. *The Kolb learning style inventory*. [S.l.]: Hay Resources Direct Boston, MA, 2007.
- KORKMAZ, C.; CORREIA, A.-P. A review of research on machine learning in educational technology. *Educational Media International*, Taylor & Francis, v. 56, n. 3, p. 250–267, 2019.
- KOZIERKIEWICZ-HETMAŃSKA, A. A method for scenario recommendation in intelligent e-learning systems. *Cybernetics and Systems: An International Journal*, Taylor & Francis, v. 42, n. 2, p. 82–99, 2011.
- KRAMER, O.; KRAMER, O. Scikit-learn. *Machine learning for evolution strategies*, Springer, p. 45–53, 2016.
- KRATHWOHL, D. R. A revision of bloom's taxonomy: An overview. *Theory into practice*, Taylor & Francis, v. 41, n. 4, p. 212–218, 2002.
- LAVBIČ, D.; MATEK, T.; ZRNEC, A. Recommender system for learning sql using hints. *Interactive Learning Environments*, Taylor & Francis, v. 25, n. 8, p. 1048–1064, 2017.

- LEITE, B. et al. Factual question generation for the portuguese language. In: IEEE. *2020 International Conference on INnovations in Intelligent SysTems and Applications (INISTA)*. [S.l.], 2020. p. 1–7.
- LI, J. et al. Pretrained language models for text generation: A survey. *arXiv preprint arXiv:2201.05273*, 2022.
- LIKERT, R. A technique for the measurement of attitudes. *Archives of psychology*, v. 140, p. 1–55, 1932.
- LIU, S. et al. Towards smart educational recommendations with reinforcement learning in classroom. In: IEEE. *2018 IEEE International Conference on Teaching, Assessment, and Learning for Engineering (TALE)*. [S.l.], 2018. p. 1079–1084.
- MASOOD, M.; MOKMIN, N. A. M. Case-based reasoning intelligent tutoring system: An application of big data and iot. In: *Proceedings of the 2017 International Conference on Big Data Research*. [S.l.: s.n.], 2017. p. 28–32.
- MEENAKSHI, K. et al. An intelligent smart tutor system based on emotion analysis and recommendation engine. In: IEEE. *2017 International Conference on IoT and Application (ICIOT)*. [S.l.], 2017. p. 1–4.
- MESSICK, S. Multiple intelligences or multilevel intelligence? selective emphasis on distinctive properties of hierarchy: On gardner’s frames of mind and steinberg’s beyond iq in the context of theory and research on the structure of human abilities. *Psychological Inquiry*, Taylor & Francis, v. 3, n. 4, p. 365–384, 1992.
- MOUSAVINASAB, E. et al. Intelligent tutoring systems: a systematic review of characteristics, applications, and evaluation methods. *Interactive Learning Environments*, Taylor & Francis, p. 1–22, 2018.
- MUMFORD, A.; HONEY, P. Questions and answers on learning styles questionnaire. *Industrial and Commercial Training*, MCB UP Ltd, v. 24, n. 7, 1992.
- NANCEKIVELL, S. E.; SHAH, P.; GELMAN, S. A. Maybe they’re born with it, or maybe it’s experience: Toward a deeper understanding of the learning style myth. *Journal of Educational Psychology*, v. 112, n. 2, p. 221–235, 2020.
- NUNES, A. I. B. L.; SILVEIRA, R. do N. Psicologia da aprendizagem. *História*, v. 9, n. 3, 2015.
- PALLAPU, P. Effects of visual and verbal learning styles on learning. *Institute for Learning Styles Journal*, v. 1, n. 1, p. 34–41, 2007.
- PIAGET, J. *Origin of Intelligence in the Child: Selected Works vol 3*. [S.l.]: Routledge, 2013.
- PIAGET, J.; COOK, M. et al. *The origins of intelligence in children*. [S.l.]: International Universities Press New York, 1952. v. 8.
- PINTO, J. Psicologia da aprendizagem, hoje. *Formar: Revista dos Formadores*, IEFP-Instituto do Emprego e Formação Profissional, p. 6–15, 1990.

- PIRES, R. et al. Sabiá: Portuguese large language models. In: SPRINGER. *Brazilian Conference on Intelligent Systems*. [S.l.], 2023. p. 226–240.
- POLLOCK, A.; BERGE, E. How to do a systematic review. *International Journal of Stroke*, SAGE Publications Sage UK: London, England, v. 13, n. 2, p. 138–156, 2018.
- RADFORD, A. et al. Language models are unsupervised multitask learners. *OpenAI Blog*, v. 1, n. 8, p. 9, 2019.
- SANTOS, L. J. d. *Como os alunos estudam: tendências em estilos de aprendizagem dos estudantes dos cursos de Química da UnB*. Dissertação (TCC) — UnB, 2022.
- SHAH, R.; SHAH, D.; KURUP, L. Automatic question generation for intelligent tutoring systems. In: IEEE. *2017 2nd International Conference on Communication Systems, Computing and IT Applications (CSCITA)*. [S.l.], 2017. p. 127–132.
- SILVEIRA, N. *Taxonomia de Bloom: o sistema que pode ajudar a organizar as aulas*. 2023. <https://desafiosdaeducacao.com.br/taxonomia-de-bloom/>. Acesso em: 03 de junho de 2024.
- SINGHAL, R.; GOYAL, S.; HENZ, M. User-defined difficulty levels for automated question generation. In: IEEE. *2016 IEEE 28th International Conference on Tools with Artificial Intelligence (ICTAI)*. [S.l.], 2016. p. 828–835.
- SOSNOWSKI, T.; YORDANOVA, K. A probabilistic conversational agent for intelligent tutoring systems. In: *Proceedings of the 13th ACM International Conference on Pervasive Technologies Related to Assistive Environments*. [S.l.: s.n.], 2020. p. 1–7.
- SOUZA, M. T. C. C. d. As relações entre afetividade e inteligência no desenvolvimento psicológico. *Psicologia: teoria e pesquisa*, SciELO Brasil, v. 27, p. 249–254, 2011.
- SOUZA, T. *A Teoria das Inteligências Múltiplas de Gardner*. 2015. (<https://psiconline.com/2015/05/teoria-das-inteligencias-multiplas-de-gardner.html>). Acesso em: 03 de junho de 2024.
- SPANELLA, T. Visual learning style: Definition & characteristics. *Retrieved from: study.com/academy/lesson/visual-learning-style-definition-characteristics.html*, 2013.
- STERNBERG, R. J. *Beyond IQ: A triarchic theory of human intelligence*. [S.l.]: CUP Archive, 1985.
- STERNBERG, R. J. Allowing for thinking styles. *Educational leadership*, ERIC, v. 52, n. 3, p. 36–40, 1994.
- STERNBERG, R. J.; GRIGORENKO, E. L. Are cognitive styles still in style? *American psychologist*, American Psychological Association, v. 52, n. 7, p. 700, 1997.

THELEN, H. A. Experimental research toward a theory of instruction. *The Journal of Educational Research*, Taylor & Francis, v. 45, n. 2, p. 89–93, 1951.

TIAM-LEE, T. J.; SUMI, K. Procedural generation of programming exercises with guides based on the student's emotion. In: IEEE. *2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*. [S.l.], 2018. p. 1465–1470.

TOUVRON, H. et al. Llama: Open and efficient foundation language models. *arXiv preprint arXiv:2302.13971*, 2023.

TROUSSAS, C.; KROUSKA, A.; VIRVOU, M. Adaptive e-learning interactions using dynamic clustering of learners' characteristics. In: IEEE. *2019 10th International Conference on Information, Intelligence, Systems and Applications (IISA)*. [S.l.], 2019. p. 1–7.

VANLEHN, K. The relative effectiveness of human tutoring, intelligent tutoring systems, and other tutoring systems. *Educational Psychologist*, Taylor & Francis, v. 46, n. 4, p. 197–221, 2011.

VERDÚ, E. et al. Intelligent tutoring interface for technology enhanced learning in a course of computer network design. In: IEEE. *2014 IEEE Frontiers in Education Conference (FIE) Proceedings*. [S.l.], 2014. p. 1–7.

WONG, L.-H.; LOOI, C.-K. Swarm intelligence: new techniques for adaptive systems to provide learning support. *Interactive Learning Environments*, Taylor & Francis, v. 20, n. 1, p. 19–40, 2012.

WU, S. et al. An intelligent tutoring system for math word problem solving with tutorial solution generation. In: IEEE. *2022 International Conference on Intelligent Education and Intelligent Research (IEIR)*. [S.l.], 2022. p. 183–188.

YAN, Y. et al. A method for personalized C programming learning contents recommendation to enhance traditional instruction. In: IEEE. *2017 IEEE 31st International Conference on Advanced Information Networking and Applications (AINA)*. [S.l.], 2017. p. 320–327.

ZHANG, Q. et al. Ai-powered text generation for harmonious human-machine interaction: Current state and future directions. In: IEEE. *2019 IEEE SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computing, Scalable Computing & Communications, Cloud & Big Data Computing, Internet of People and Smart City Innovation (SmartWorld/SCALCOM/UIC/ATC/CBDCom/IOP/SCI)*. [S.l.], 2019. p. 859–864.

ZHANG, Y. et al. Evov: A video recommendation system to support sustainable vocabulary learning. In: IEEE. *2015 IEEE International Conference on Teaching, Assessment, and Learning for Engineering (TALE)*. [S.l.], 2015. p. 43–48.

ZHIPING, L.; YU, S.; TIANWEI, X. A formal model of personalized recommendation systems in intelligent tutoring systems. In: IEEE. *2011 6th International Conference on Computer Science & Education (ICCSE)*. [S.l.], 2011. p. 1006–1009.

Apêndice A - Inventário de estilos de aprendizagem de Kolb

O questionário definido por Kolb é composto por um conjunto de afirmações que tem quatro possibilidades de respostas, sendo que estas devem ser classificadas de acordo com uma escala de preferência durante a experiência individual de aprendizagem.

Cada possibilidade de respostas do questionário é classificada em uma escala que pode variar, de 1 a 4, onde 1 indica a menor preferência e 4 a maior preferência. O objetivo é pontuar como cada pessoa prefere aprender e processar novas informações.

Para avaliação das respostas, as pontuações de cada item são somadas e comparadas entre as quatro categorias do modelo, experiência concreta, observação reflexiva, conceitualização abstrata e experimentação ativa (EC, OR, CA e EA). A combinação dessas pontuações revela a inclinação de um indivíduo para um ou mais estilos de aprendizagem.

As perguntas do questionário são exibidas a seguir:

Tabela 9: Questionário do Modelo de Kolb

Questão	Itens
Quando aprendo	(a) gosto de trabalhar meus sentidos (b) gosto de ouvir e escutar (c) gosto de pensar nos conceitos (d) gosto de estar fazendo coisas
Aprendo melhor quando	(a) confio em meus sentimentos (b) observo e escuto atentamente (c) me baseio em raciocínio lógico (d) trabalho para ver as coisas prontas
Quando estou aprendendo	(a) tenho sentimentos e reações fortes (b) sou quieto e reservado (c) procuro colocar razões nas coisas (d) sou responsável pelas coisas

Aprendo por	(a) sentimento (b) observação (c) pensamento (d) ação
Quando eu aprendo	(a) estou pronto para novas experiências (b) examino todos os lados da questão (c) procuro analisar as coisas e dividi-las em partes (d) gosto de experimentar as coisas
Quando estou aprendendo	(a) sou intuitivo (b) sou observador (c) sou lógico (d) sou ativo
Aprendo melhor a partir de	(a) relacionamentos pessoais (b) observação (c) teorias racionais (d) uma chance de praticar e experimentar
Aprendo melhor quando	(a) me baseio em meus sentimentos (b) me baseio em minhas observações (c) me baseio em minhas ideias (d) posso experimentar coisas
Quando estou aprendendo	(a) sou receptivo (b) sou reservado (c) sou racional (d) sou responsável
Quando aprendo	(a) me envolvo (b) observo (c) avalio (d) sou ativo
Aprendo melhor quando	(a) estou receptivo e aberto (b) estou cuidadoso (c) analise as ideias (d) sou prático


A soma de cada item representará a pontuação de um eixo, sendo:

- Item a - Soma de pontos para o eixo de experiência concreta;

- Item b - Soma de pontos para o eixo de observação reflexiva;
- Item c - Soma de pontos para o eixo de conceitualização abstrata;
- Item d - Soma de pontos para o eixo de experimentação ativa.

Para encontrar o estilo que mais se adequará, é necessário encontrar o ponto (x,y) nos eixos demarcados pela Figura 13. O eixo X é calculado pela subtração dos pontos EA - OR, e o y é a subtração CA - EC, a localização deste ponto definirá o quadrante o estilo.

Figura 13: Ilustração do gráfico idealizado por Kolb



Fonte: Adaptado de (KOLB, 1985))

Este processo é padronizado, sendo também uma forma de generalizar a aplicação do teste e encontrar facilmente um estilo mais adequado.

Apêndice B - Materiais aplicados para os testes de observação

Esta seção exibe os textos aplicados para o teste de observação, assim como as suas versões adaptadas que foram produzidas com as técnicas aplicadas.

O texto original utilizado é o mesmo para gerar as quatro versões adaptadas, e representa um artigo para abordar algoritmos genéticos.

In computer science and operations research, a genetic algorithm (GA) is a metaheuristic inspired by the process of natural selection that belongs to the larger class of evolutionary algorithms (EA). Genetic algorithms are commonly used to generate high-quality solutions to optimization and search problems by relying on biologically inspired operators such as mutation, crossover and selection. Some examples of GA applications include optimizing decision trees for better performance, solving sudoku puzzles, hyperparameter optimization, etc.

Optimization problems

In a genetic algorithm, a population of candidate solutions (called individuals, creatures, organisms, or phenotypes) to an optimization problem is evolved toward better solutions. Each candidate solution has a set of properties (its chromosomes or genotype) which can be mutated and altered; traditionally, solutions are represented in binary as strings of 0s and 1s, but other encodings are also possible.

The evolution usually starts from a population of randomly generated individuals, and is an iterative process, with the population in each iteration called a generation. In each generation, the fitness of every individual in the population is evaluated; the fitness is usually the value of the objective function in the optimization problem being solved. The more fit individuals are stochastically selected from the current population, and each individual's genome is modified (recombined and possibly randomly mutated) to form a new generation. The new generation of candidate solutions is then used in the next iteration of the

algorithm. Commonly, the algorithm terminates when either a maximum number of generations has been produced, or a satisfactory fitness level has been reached for the population.

A typical genetic algorithm requires: a genetic representation of the solution domain, a fitness function to evaluate the solution domain.

A standard representation of each candidate solution is as an array of bits (also called bit set or bit string). Arrays of other types and structures can be used in essentially the same way. The main property that makes these genetic representations convenient is that their parts are easily aligned due to their fixed size, which facilitates simple crossover operations. Variable length representations may also be used, but crossover implementation is more complex in this case. Tree-like representations are explored in genetic programming and graph-form representations are explored in evolutionary programming; a mix of both linear chromosomes and trees is explored in gene expression programming.

Once the genetic representation and the fitness function are defined, a GA proceeds to initialize a population of solutions and then to improve it through repetitive application of the mutation, crossover, inversion and selection operators.

Initialization

The population size depends on the nature of the problem, but typically contains several hundreds or thousands of possible solutions. Often, the initial population is generated randomly, allowing the entire range of possible solutions (the search space). Occasionally, the solutions may be "seeded" in areas where optimal solutions are likely to be found.

Selection

During each successive generation, a portion of the existing population is selected to breed a new generation. Individual solutions are selected through a fitness-based process, where fitter solutions (as measured by a fitness function) are typically more likely to be selected. Certain selection methods rate the fitness of each solution and preferentially select the best solutions. Other methods rate only a random sample of the population, as the former process may be very time-consuming.

The fitness function is defined over the genetic representation and measures the quality of the represented solution. The fitness function is always problem dependent. For instance, in the knapsack problem one wants to maximize the total value of objects that can be put in a knapsack of some fixed capacity. A representation of a solution might be an array of bits, where each bit represents a different object, and the value of the bit (0 or 1) represents whether or not

the object is in the knapsack. Not every such representation is valid, as the size of objects may exceed the capacity of the knapsack. The fitness of the solution is the sum of values of all objects in the knapsack if the representation is valid, or 0 otherwise.

In some problems, it is hard or even impossible to define the fitness expression; in these cases, a simulation may be used to determine the fitness function value of a phenotype (e.g. computational fluid dynamics is used to determine the air resistance of a vehicle whose shape is encoded as the phenotype), or even interactive genetic algorithms are used.

Genetic operators

The next step is to generate a second generation population of solutions from those selected, through a combination of genetic operators: crossover (also called recombination), and mutation.

For each new solution to be produced, a pair of "parent" solutions is selected for breeding from the pool selected previously. By producing a "child" solution using the above methods of crossover and mutation, a new solution is created which typically shares many of the characteristics of its "parents". New parents are selected for each new child, and the process continues until a new population of solutions of appropriate size is generated. Although reproduction methods that are based on the use of two parents are more "biology inspired", some research suggests that more than two "parents" generate higher quality chromosomes.

These processes ultimately result in the next generation population of chromosomes that is different from the initial generation. Generally, the average fitness will have increased by this procedure for the population, since only the best organisms from the first generation are selected for breeding, along with a small proportion of less fit solutions. These less fit solutions ensure genetic diversity within the genetic pool of the parents and therefore ensure the genetic diversity of the subsequent generation of children.

Opinion is divided over the importance of crossover versus mutation. There are many references in Fogel (2006) that support the importance of mutation-based search. Although crossover and mutation are known as the main genetic operators, it is possible to use other operators such as regrouping, colonization-extinction, or migration in genetic algorithms.

It is worth tuning parameters such as the mutation probability, crossover probability and population size to find reasonable settings for the problem class being worked on. A very small mutation rate may lead to genetic drift (which is non-ergodic in nature). A recombination rate that is too high may lead to

premature convergence of the genetic algorithm. A mutation rate that is too high may lead to loss of good solutions, unless elitist selection is employed. An adequate population size ensures sufficient genetic diversity for the problem at hand, but can lead to a waste of computational resources if set to a value larger than required.

Heuristics

In addition to the main operators above, other heuristics may be employed to make the calculation faster or more robust. The speciation heuristic penalizes crossover between candidate solutions that are too similar; this encourages population diversity and helps prevent premature convergence to a less optimal solution.

Termination

This generational process is repeated until a termination condition has been reached. Common terminating conditions are: A solution is found that satisfies minimum criteria; Fixed number of generations reached; Allocated budget (computation time/money) reached; The highest ranking solution's fitness is reaching or has reached a plateau such that successive iterations no longer produce better results; Manual inspection; Combinations of the above.

Genetic algorithms are simple to implement, but their behavior is difficult to understand. In particular, it is difficult to understand why these algorithms frequently succeed at generating solutions of high fitness when applied to practical problems. The building block hypothesis (BBH) consists of: A description of a heuristic that performs adaptation by identifying and recombining "building blocks", i.e. low order, low defining-length schemata with above average fitness; A hypothesis that a genetic algorithm performs adaptation by implicitly and efficiently implementing this heuristic.

A versão adaptada para o modelo assimilador é a mais próxima do texto original, sendo aplicadas algumas técnicas de redução do texto, mas mantendo ainda muito material de leitura, que é a preferência do estilo.

Some examples of GA applications include optimizing decision trees for better performance, solving sudoku puzzles, hyperparameter optimization, etc.

The evolution usually starts from a population of randomly generated individuals, and is an iterative process, with the population in each iteration called a generation. In each generation, the fitness of every individual in the population is evaluated; the fitness is usually the value of the objective function in the optimization problem being solved. The more fit individuals are stochastically

selected from the current population, and each individual's genome is modified (recombined and possibly randomly mutated) to form a new generation. The new generation of candidate solutions is then used in the next iteration of the algorithm. Commonly, the algorithm terminates when either a maximum number of generations has been produced, or a satisfactory fitness level has been reached for the population. A typical genetic algorithm requires: a genetic representation of the solution domain, a fitness function to evaluate the solution domain. A standard representation of each candidate solution is as an array of bits (also called bit set or bit string). Arrays of other types and structures can be used in essentially the same way. The main property that makes these genetic representations convenient is that their parts are easily aligned due to their fixed size, which facilitates simple crossover operations. Variable length representations may also be used, but crossover implementation is more complex in this case. Tree-like representations are explored in genetic programming and graph form representations are explored in evolutionary programming; a mix of both linear chromosomes and trees is explored in gene expression programming.

Initialization The population size depends on the nature of the problem, but typically contains several hundreds or thousands of possible solutions. Often, the initial population is generated randomly, allowing the entire range of possible solutions (the search space). Occasionally, the solutions may be "seeded" in areas where optimal solutions are likely to be found.

Selection

During each successive generation, a portion of the existing population is selected to breed a new generation. Individual solutions are selected through a fitness-based process, where fitter solutions (as measured by a fitness function) are typically more likely to be selected. Certain selection methods rate the fitness of each solution and preferentially select the best solutions. Other methods rate only a random sample of the population, as the former process may be very time-consuming.

The fitness function is defined over the genetic representation and measures the quality of the represented solution. The fitness function is always problem dependent. For instance, in the knapsack problem one wants to maximize the total value of objects that can be put in a knapsack of some fixed capacity. A representation of a solution might be an array of bits, where each bit represents a different object, and the value of the bit (0 or 1) represents whether or not the object is in the knapsack. Not every such representation is valid, as the size of objects may exceed the capacity of the knapsack. The fitness of the solution is the sum of values of all objects in the knapsack if the representation is valid,

or 0 otherwise. In some problems, it is hard or even impossible to define the fitness expression; in these cases, a simulation may be used to determine the fitness function value of a phenotype (e.g. computational fluid dynamics is used to determine the air resistance of a vehicle whose shape is encoded as the phenotype), or even interactive genetic algorithms are used.

For each new solution to be produced, a pair of "parent" solutions is selected for breeding from the pool selected previously. By producing a "child" solution using the above methods of crossover and mutation, a new solution is created which typically shares many of the characteristics of its "parents". New parents are selected for each new child, and the process continues until a new population of solutions of appropriate size is generated. Although reproduction methods that are based on the use of two parents are more "biology inspired", some research suggests that more than two "parents" generate higher quality chromosomes. These processes ultimately result in the next generation population of chromosomes that is different from the initial generation. Generally, the average fitness will have increased by this procedure for the population, since only the best organisms from the first generation are selected for breeding, along with a small proportion of less fit solutions. These less fit solutions ensure genetic diversity within the genetic pool of the parents and therefore ensure the genetic diversity of the subsequent generation of children. Opinion is divided over the importance of crossover versus mutation. There are many references in Fogel (2006) that support the importance of mutation-based search. Although crossover and mutation are known as the main genetic operators, it is possible to use other operators such as regrouping, colonization-extinction, or migration in genetic algorithms. It is worth tuning parameters such as the mutation probability, crossover probability and population size to find reasonable settings for the problem class being worked on. A very small mutation rate may lead to genetic drift (which is non ergodic in nature). A recombination rate that is too high may lead to premature convergence of the genetic algorithm. A mutation rate that is too high may lead to loss of good solutions, unless elitist selection is employed. An adequate population size ensures sufficient genetic diversity for the problem at hand, but can lead to a waste of computational resources if set to a value larger than required. Heuristics In addition to the main operators above, other heuristics may be employed to make the calculation faster or more robust. The speciation heuristic penalizes crossover between candidate solutions that are too similar; this encourages population diversity and helps prevent premature convergence to a less optimal solution.

Termination

This generational process is repeated until a termination condition has been reached.

O estilo convergente é bem próximo do estilo assimilador quanto a material de leitura. No entanto, este estilo gosta de aprender por tentativa e erro.

Por este motivo, o estilo convergente recebeu um texto marcado por pontos de destaque e noções básicas, para que pudesse realizar um teste com questões. Este estilo recebeu como apoio, na exibição final, o mesmo texto do estilo Assimilador, apenas como suporte para ser consultado.

Tópicos de Destaque:

Arrays of other types and structures can be used in essentially the same way. Tree-like representations are explored in genetic programming and graph-form representations are explored in evolutionary programming; a mix of both linear chromosomes and trees is explored in gene expression programming. Certain selection methods rate the fitness of each solution and preferentially select the best solutions. The fitness function is defined over the genetic representation and measures the quality of the represented solution. The fitness function is always problem dependent. Opinion is divided over the importance of crossover versus mutation. There are many references in Fogel (2006) that support the importance of mutation-based search.

Termination

This generational process is repeated until a termination condition has been reached.

- genetic
- algorithms
- evolutionary

In computer science and operations research, a genetic algorithm (GA) is a metaheuristic inspired by the process of natural selection that belongs to the larger class of evolutionary algorithms (EA)

Genetic algorithms are commonly used to generate high-quality solutions to optimization and search problems by relying on biologically inspired operators such as mutation, crossover and selection

Tree-like representations are explored in genetic programming and graph-form representations are explored in evolutionary programming; a mix of both linear chromosomes and trees is explored in gene expression programming

O estilo divergente se interessa por aprendizado que permita encontrar motivações pessoais, e que possa direcionar para o que é do seu interesse.

Por este motivo, o texto apresentada para este estilo começa com os tópicos (temas) que são abordados e demarca estes temas ao longo do texto. Desta forma o estudante poderia ir diretamente ao trecho que gostaria de entender primeiro

Tópicos do Tema:

- GENETIC ALGORITHMS
- TYPICAL GENETIC ALGORITHM
- CERTAIN SELECTION METHODS
- FITNESS FUNCTION
- GENETIC POOL
- TERMINATION CONDITION

Sumarização por tópicos

GENETIC ALGORITHMS In computer science and operations research, a genetic algorithm (GA) is a metaheuristic inspired by the process of natural selection that belongs to the larger class of evolutionary algorithms (EA). Genetic algorithms are commonly used to generate high-quality solutions to optimization and search problems by relying on biologically inspired operators such as mutation, crossover and selection. Some examples of GA applications include optimizing decision trees for better performance, solving sudoku puzzles, hyperparameter optimization, etc.

Optimization problems

In a genetic algorithm, a population of candidate solutions (called individuals, creatures, organisms, or phenotypes) to an optimization problem is evolved toward better solutions. Each candidate solution has a set of properties (its chromosomes or genotype) which can be mutated and altered; traditionally, solutions are represented in binary as strings of 0s and 1s, but other encodings are also possible.

TYPICAL GENETIC ALGORITHM

The evolution usually starts from a population of randomly generated individuals, and is an iterative process, with the population in each iteration called a generation. The new generation of candidate solutions is then used in the next iteration of the algorithm. Commonly, the algorithm terminates when either a maximum number of generations has been produced, or a satisfactory fitness level has been reached for the population. A typical genetic algorithm requires: a genetic representation of the solution domain, a fitness function to evaluate the solution domain. A standard representation of each candidate solution is as an array of bits (also called bit set or bit string). Arrays of other types and structures can be used in essentially the same way. The main property that makes

these genetic representations convenient is that their parts are easily aligned due to their fixed size, which facilitates simple crossover operations. Variable length representations may also be used, but crossover implementation is more complex in this case. Tree-like representations are explored in genetic programming and graph-form representations are explored in evolutionary programming; a mix of both linear chromosomes and trees is explored in gene expression programming. Initialization The population size depends on the nature of the problem, but typically contains several hundreds or thousands of possible solutions. Occasionally, the solutions may be "seeded" in areas where optimal solutions are likely to be found.

CERTAIN SELECTION METHODS

Selection

During each successive generation, a portion of the existing population is selected to breed a new generation. Individual solutions are selected through a fitness-based process, where fitter solutions (as measured by a fitness function) are typically more likely to be selected. Certain selection methods rate the fitness of each solution and preferentially select the best solutions. Other methods rate only a random sample of the population, as the former process may be very time-consuming.

FITNESS FUNCTION

The fitness function is defined over the genetic representation and measures the quality of the represented solution. The fitness function is always problem dependent. For instance, in the knapsack problem one wants to maximize the total value of objects that can be put in a knapsack of some fixed capacity. A representation of a solution might be an array of bits, where each bit represents a different object, and the value of the bit (0 or 1) represents whether or not the object is in the knapsack. Not every such representation is valid, as the size of objects may exceed the capacity of the knapsack. The fitness of the solution is the sum of values of all objects in the knapsack if the representation is valid, or 0 otherwise. computational fluid dynamics is used to determine the air resistance of a vehicle whose shape is encoded as the phenotype), or even interactive genetic algorithms are used. Genetic operators The next step is to generate a second generation population of solutions from those selected, through a combination of genetic operators: crossover (also called recombination), and mutation.

GENETIC POOL

For each new solution to be produced, a pair of "parent" solutions is selected for breeding from the pool selected previously. New parents are selected for each new child, and the process continues until a new population of solutions of

appropriate size is generated. Although reproduction methods that are based on the use of two parents are more "biology inspired", some research suggests that more than two "parents" generate higher quality chromosomes. These processes ultimately result in the next generation population of chromosomes that is different from the initial generation. These less fit solutions ensure genetic diversity within the genetic pool of the parents and therefore ensure the genetic diversity of the subsequent generation of children. Opinion is divided over the importance of crossover versus mutation. There are many references in Fogel (2006) that support the importance of mutation-based search. Although crossover and mutation are known as the main genetic operators, it is possible to use other operators such as regrouping, colonization-extinction, or migration in genetic algorithms. It is worth tuning parameters such as the mutation probability, crossover probability and population size to find reasonable settings for the problem class being worked on. A very small mutation rate may lead to genetic drift (which is non-ergodic in nature). A recombination rate that is too high may lead to premature convergence of the genetic algorithm. A mutation rate that is too high may lead to loss of good solutions, unless elitist selection is employed. Heuristics In addition to the main operators above, other heuristics may be employed to make the calculation faster or more robust. The speciation heuristic penalizes crossover between candidate solutions that are too similar; this encourages population diversity and helps prevent premature convergence to a less optimal solution.

TERMINATION CONDITION

Termination

This generational process is repeated until a termination condition has been reached. Common terminating conditions are: A solution is found that satisfies minimum criteria; Fixed number of generations reached; Allocated budget (computation time/money) reached; The highest ranking solution's fitness is reaching or has reached a plateau such that successive iterations no longer produce better results; Manual inspection; Combinations of the above.

Por fim, o estilo acomodador que gosta de pouco material de leitura, sendo apenas direcionado. Recebeu um único tópico para contextualização e indicadores de Tags para pesquisa.

Tópico

Arrays of other types and structures can be used in essentially the same way. Tree-like representations are explored in genetic programming and graph-form

representations are explored in evolutionary programming; a mix of both linear chromosomes and trees is explored in gene expression programming. Certain selection methods rate the fitness of each solution and preferentially select the best solutions. The fitness function is defined over the genetic representation and measures the quality of the represented solution. The fitness function is always problem dependent. Opinion is divided over the importance of crossover versus mutation. There are many references in Fogel (2006) that support the importance of mutation based search.

Termination This generational process is repeated until a termination condition has been reached.

Apêndice C - Avaliação da Pesquisa - Formulário

Para a realização do teste de observação, cada voluntário participante recebeu um questionário, por meio do qual deveria responder seu nível de concordância com cada afirmação.

As afirmações para avaliação foram:

1. Eu já conhecia o conteúdo abordado.
2. Tenho interesse no tema abordado.
3. Me senti confortável com o formato de apresentação do conteúdo.
4. Me senti confortável com a ordem de apresentação do conteúdo.
5. Me senti confortável com os tipos de apresentação escolhidos (texto, questões e tópicos)
6. O modelo apresentado atendeu as minhas preferencias de aprendizagem.
7. Quando estudo sozinho, gosto de adotar um formato semelhante ao modelo que recebi.
8. Considero o texto apresentado um direcionador de estudo do tema.
9. Considero o texto apresentado um complemento e/ou uma fonte extra para o estudo do tema.
10. O texto apresentado foi claro.
11. Os tópicos apresentados resumiram bem os pontos principais e pontos de atenção.
12. As questões foram uma prática interessante para o aprendizado.

Para cada item foi possível escolher apenas uma entre as alternativas de: Discordo Totalmente, Discordo Parcialmente, Não concordo e Não discordo, Concordo Parcialmente e Concordo Totalmente.