

## Modelo de adaptação de conteúdo individualizada com base em estilos de aprendizagem

Fernanda F. Peronaglio<sup>1</sup>, Aleardo Manacero Jr.<sup>1</sup>, Alexandro J. Baldassin<sup>1</sup>,  
Matheus S. dos Santos<sup>1</sup>, Renata S. Lobato<sup>1</sup>, Roberta Spolon<sup>1</sup>, Marcos A. Cavenaghi<sup>2</sup>

<sup>1</sup>Universidade Estadual Paulista “Júlio de Mesquita Filho”

<sup>2</sup>Humber Inst. Tec and Adv. Learning, Canada

{fernanda.peronaglio, aleardo.manacero, alexandro.baldassin}@unesp.br

{matheus.santi, renata.lobato, roberta.spolon}@unesp.br

marcos.cavenaghi@humber.ca

**Resumo.** O uso de sistemas inteligentes tem se ampliado notavelmente desde a introdução de novas técnicas de aprendizado de máquina, sendo isso reforçado a partir do surgimento das LLMs (Large Language Models). Esse crescimento tem se observado também em ensino, que é uma área em que já há bastante tempo se introduziu os Sistemas Tutores Inteligentes. Neste contexto, uma aplicação interessante é a geração de conteúdos adaptados a estilos de aprendizagem, em que um material didático é produzido de forma customizada para cada categoria de aluno. Apresenta-se aqui uma ferramenta que usa técnicas de inteligência artificial para construção de conteúdos adaptados para o Inventário de Estilos de Aprendizagem criado por David Kolb. Essa ferramenta automatiza a produção de conteúdos específicos para cada estilo a partir de um texto base introduzido pelo professor. Os resultados obtidos mostram que o uso de LLMs permite a criação de textos específicos com facilidade, viabilizando ao professor produzir textos adaptados a cada perfil de aluno.

**Abstract.** The use of intelligent systems has expanded notably since the introduction of new machine learning techniques, a trend further reinforced by the emergence of Large Language Models (LLMs). This growth has also been observed in education, an area where Intelligent Tutoring Systems have been introduced for quite some time. In this context, an interesting application is the generation of content tailored to learning styles, where educational material is produced in a customized manner for each category of student. Presented here is a tool that uses artificial intelligence techniques to construct content adapted to the Learning Styles Inventory created by David Kolb. This tool automates the production of specific content for each style based on a base text provided by the teacher. The results obtained demonstrate that using LLMs enables the creation of specific texts with ease, allowing teachers to produce texts adapted to each student's profile.

### 1. Introdução

Sistemas tutores inteligentes [Corbett et al. 1997] são uma forma de ferramenta importante como apoio digital ao ensino. Neles, dois componentes são fundamentais para

a sua eficácia, que são sua interface e os conteúdos oferecidos, sendo que os mesmos devem, preferencialmente ser adaptáveis e facilitar a compreensão do que se estuda [Hämäläinen and Vinni 2006]. Em particular, a produção de conteúdos adaptáveis é uma tarefa complexa e difícil de ser automatizada. Boa parte dos sistemas tutores tem a produção de conteúdos limitada à recomendação de conteúdo já existente em um formato padrão.

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.

Considerando que a oferta de abordagens distintas é um requisito para que o ensino baseado em estilos de aprendizagem seja habilitado [Coffield et al. 2004]. 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, óbvio). Fica claro que é interessante que se possa criar conteúdos adequados a cada estilo de forma automática.

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 linguagem natural e de inteligência artificial. 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 criar novas apresentações de conteúdo direcionadas para os estilos de aprendizagem definidos, os quais seriam automaticamente inseridos em um tutor inteligente.

Na próxima seção detalha-se os principais objetivos deste trabalho e suas motivações. Nas seções seguintes apresenta-se os principais trabalhos relacionados, a definição do Inventário de Estilos de Aprendizagem proposto por Kolb [Kolb 1976], o desenvolvimento de uma ferramenta para a geração de conteúdos segundo este inventário, assim como os resultados obtidos.

Este texto está dividido em 7 seções, sendo esta a responsável pelo contexto. A seção 2 apresenta a motivação e objetivo deste trabalho e é seguida pela seção 3 com a apresentação de trabalhos relacionados. O modelo de estilo de aprendizagem escolhido e a metodologia definida para adaptação automatizada do modelo são apresentados na seção 4, e os aspectos técnicos apresentados na seção de número 5. Por fim, as seções 6 e 7 apresentam os resultados e as discussões quanto as redes generativas, e as conclusões seguem na seção 8.

## **2. Motivação e Objetivos**

Um grande número de sistemas tutores inteligentes têm sido propostos ao longo dos anos. Muitos deles possuem algum nível de adaptabilidade, como será apresentado na próxima seção, mas principalmente preocupados apenas com características ambientais, como cores ou sons, ou com a ordenação de eventos, ou seja, permitindo que os alunos abordem os

conteúdos seguindo seu próprio caminho. A adaptação real do conteúdo geralmente fica restrita a um pequeno conjunto de recursos, como a geração de perguntas, por exemplo, mas não a criação de textos personalizados.

Na verdade, os Intelligent Tutoring Systems (ITS) existentes não lidam com a geração de conteúdos de uma forma flexível. Atualmente, a manipulação de conteúdo pelos ITSs preocupa-se principalmente com a recomendação de conteúdo, ou seja, fornecer conteúdo baseado em análises estatísticas de grandes bases de dados.

Um número significativo de pesquisadores da psicologia educacional acredita que essas abordagens convencionais não são eficientes no processo de aprendizagem. Eles defendem que a adaptação do processo de ensino aos diferentes estilos de aprendizagem produziria melhores resultados na capacidade de aprendizagem dos alunos [Sternberg 1994]. Porém, ensinar com uma abordagem baseada em estilos de aprendizagem implica apresentar conteúdos em diferentes abordagens, o que não é uma tarefa simples de realizar. Na verdade, vários críticos ponderam que os estilos de aprendizagem não são práticos porque exigem muito esforço dos educadores nas atividades de produção de versões [Nancekivell et al. 2020].

Dado que um grande problema com os estilos de aprendizagem é a sua própria implementação, é possível concluir que a utilização de um ITS poderia ajudar. Essa ajuda viria da geração de conteúdos adaptados a cada um dos estilos definidos por uma determinada taxonomia (como Kolb [Kolb 1976], Dunn & Dunn [Dunn 1990], Felder-Silverman [Felder et al. 1988], entre outros) . Neste sentido, podem-se criar diversos tipos de conteúdos a partir de um conhecimento básico utilizando um ITS elaborado de acordo com os parâmetros dados por cada estilo.

Considerando que um ITS projetado para gerar conteúdo baseado em estilos de aprendizagem reduziria as críticas a essa metodologia, este trabalho propõe uma ferramenta que adapta conteúdo com base no Modelo de Estilos de Aprendizagem de Kolb [Kolb 1976]. Com esta abordagem, um aluno classificado em um determinado estilo receberia informações criadas para sua preferência a partir de um original convencional. Esperamos que isso possibilite uma melhor compreensão por parte dos alunos, uma vez que o conteúdo será adaptado a cada um deles.

### **3. Trabalhos Relacionados**

É possível encontrar 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.

Na literatura sobre sistemas tutores inteligentes, é possível encontrar revisões específicas sobre efetividade do sistema, técnicas de modelagem de usuário ou métodos de desenvolvimento. Para este trabalho destacam-se as revisões que abordaram características e funcionalidades dos sistemas, por manter relacionamento com as funções disponíveis para tratamento de conteúdo.

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 um visão geral de características do cenário, investigando o tipo de pesquisa realizada na área.

Relacionados as aplicações de técnicas de inteligência nestes sistemas de ensino, é possível encontrar trabalhos como o desenvolvido por Wong e Looi [Wong and Looi 2012]. A pesquisa investiga abordagens da técnica "Inteligência de Exames" 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 and Correia 2019], com uma revisão sistemática de 2007 a 2017 sobre as tendências das pesquisas de aprendizado de máquina em relação a tecnologias educacionais.

Nas pesquisas relacionadas as técnicas de geração e inferência em texto, destaca-se o trabalho de Janjanam e Reddy [Janjanam and Reddy 2019]. O estudo desenvolvido investiga a sumarização de texto, uma importante aplicação de geração de conteúdo.

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.

Além disso, fez parte das fases iniciais deste trabalho a produção de uma revisão sistemática da literatura, com o objetivo de compreender o cenário de aplicação e formular este proposta de maneira ideal.

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 [Lavbič et al. 2017], mas, ainda assim, o levantamento buscou esclarecer todas as frentes de abordagem.

Foram escolhidos apenas trabalhos entre 2010 e 2019, 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.

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 a manipulação de conteúdo feita nestas áreas, se aproximando da proposta do projeto.

Este levantamento permitiu uma visão mais completa do cenário de aplicação e das técnicas existentes. Como exemplo, é possível citar o trabalho de recomendação com base em características do usuário [Zhiping et al. 2011], e o trabalho de recomendação com base em clusterização [Troussas et al. 2019].

Entre os trabalhos observados é possível perceber que a adaptação de conteúdo proposta neste trabalho contribui para a inovação da área. Além disso, a visão alinhada aos estilos de aprendizagem é um diferencial aos trabalhos avaliados na revisão.

#### **4. Modelo de Estilos de Aprendizagem**

Como base para o trabalho foi escolhido um modelo baseado na categoria de preferências de aprendizagem, que também possui uma abordagem quantitativa para diferenciar os alunos. O modelo de Kolb [Kolb 2007] possui essas características e fornece um pequeno conjunto de perguntas para classificar os alunos, com base em respostas classificadas de acordo com suas preferências. Apesar de Kolb ter modificado sua taxonomia original ao longo dos anos, adotamos a abordagem tradicional com quatro estilos básicos denominados **Assimilador**, **Convergente**, **Acomodador** e **Divergente**.

A aplicação do modelo de Kolb começa com a classificação do aluno em uma das categorias após responder a um conjunto de 12 questões. Cada questão é uma frase inicial como “Aprendo melhor quando” ou “Quando estou aprendendo”, para a qual o aluno deve ordenar quatro terminações de acordo com sua preferência. Por exemplo, para a frase “Eu aprendo melhor quando” as conclusões possíveis são “Eu confio nos meus sentimentos”, “Eu confio na minha própria observação”, “Eu confio nas minhas próprias ideias”, e “Eu tenho que experimentar as coisas sozinho”.

A composição de todas as classificações resulta em um par de valores relacionados à forma como o aluno processa e percebe o conteúdo que está sendo ensinado. O par de valores representa um ponto em um plano de quatro quadrantes, visto na Fig. 1, onde cada estilo é mapeado para um determinado quadrante. Por exemplo, espera-se que um aluno cujas respostas levaram ao quadrante Convergente aprenda melhor ao pensar e realizar alguma atividade enquanto aprende. Nas seções a seguir descrevemos brevemente cada estilo.

O modelo, conhecido como “Ciclo de Aprendizagem Experiencial”, descreve a aprendizagem como um processo cíclico composto por quatro estágios interligados: Experiência Concreta (EC), Observação Reflexiva (OR), Conceitualização Abstrata (CA) e Experimentação Ativa (EA).

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

É possível observar que cada quadrante exibido na 1, e formado pelos estágios, são marcados por orientações para estudo direcionado.

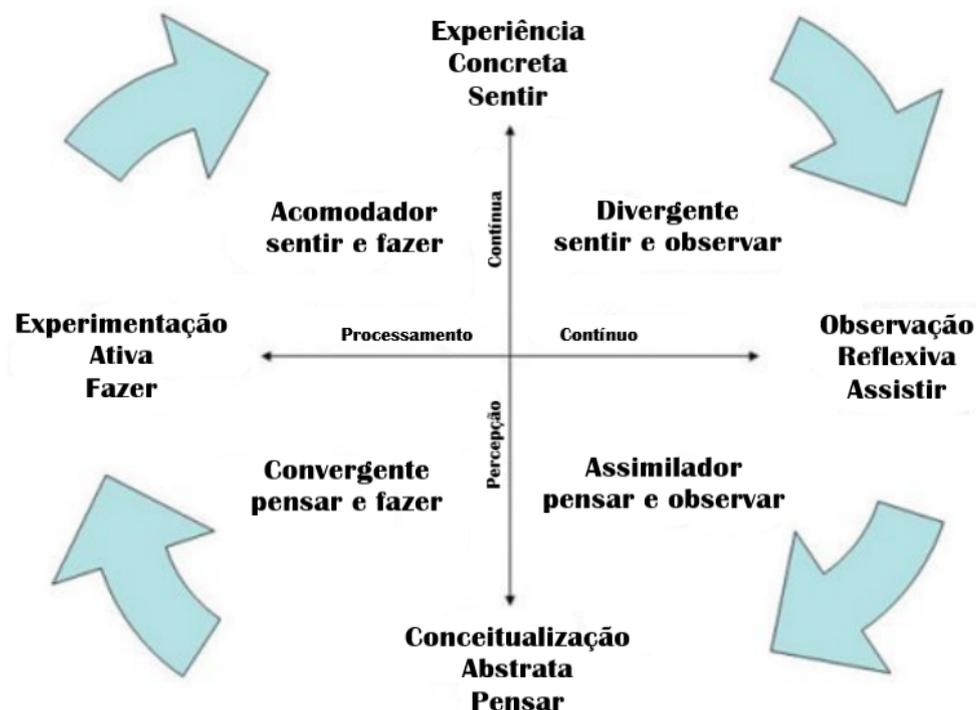


Figura 1. Modelo de Aprendizagem de Kolb (adaptado de [Idkhan and Idris 2021])

Entre os eixos exibidos anteriormente, o modelo define os estilos de aprendizagem personalizados e que melhor se adaptam as características. 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 internalizado 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 mais de uma solução

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.

#### **4.1. Modelo de adaptação caracterizado para cada estilo**

O Modelo de Kolb [Kolb 1976] fornece descrições completas sobre cada um dos quatro estilos definidos. Isso permitiu a criação de regras para determinar aspectos, como os listados na seção anterior, que devem estar presentes em um texto elaborado para um determinado estilo, e também em que ordem devem ser apresentados ao aluno, conforme mostrado a seguir.

##### **4.1.1. Assimilador**

Conforme indicado anteriormente, estes são alunos propensos a preferir a teoria à prática, devendo o material gerado ser apresentado na seguinte ordem:

- i. Texto teórico, uma vez que os assimiladores têm preferência pela teoria e pelo pensamento analítico, devem primeiro ser confrontados com um texto fundacional, mas esta será uma versão abreviada do que está nas fontes regulares.
- ii. Tópicos principais, onde é apresentado ao aluno um conjunto de frases desenhadas para apontar os aspectos teóricos mais relevantes.
- iii. Perguntas exemplares, apresentadas ao final para que o aluno verifique o quanto aprendeu com o texto teórico.

##### **4.1.2. Acomodador**

Os acomodadores preferem ações práticas em vez de teoria. Portanto, a maior parte do material produzido deve proporcionar estímulo aos alunos. As peças deverão seguir esta ordem:

- i. Texto teórico, agora restrito a poucas frases que introduzissem a ideia geral sobre o assunto.
- ii. Exemplos de perguntas, que devem ser em maior quantidade e que indicariam eventuais deficiências no conhecimento necessário.
- iii. Tópicos principais, que devem indicar tags de pesquisa orientando os alunos a buscarem livremente materiais adicionais.

##### **4.1.3. Divergente**

Os divergentes gostam de ter uma relação mais pessoal com o que estão aprendendo. Essa relação pode ser alcançada fazendo com que os alunos selecionem quais partes do material irão abordar.

- i. Tópicos principais, apresentados como um conjunto de palavras-chave, a partir das quais o aluno pode selecionar o caminho a ser seguido durante o estudo.
- ii. Texto teórico, que deverá ter seções visivelmente marcadas para as palavras-chave acabadas de apresentar, permitindo ao aluno escolher as partes selecionadas.
- iii. Complementos, compostos basicamente por links para geração de novos conteúdos sobre temas específicos.
- iv. Exemplos de perguntas, que aparecem no final, para fornecer uma autoavaliação ao aluno.

#### 4.1.4. Convergente

Alunos classificados como convergentes são menos propensos à teoria, exigindo uma inversão na ordem de apresentação, que é:

- i. Tópicos principais, permitindo ao aluno identificar quais conteúdos são mais relevantes, economizando tempo na leitura aprofundada do texto.
- ii. Exemplos de perguntas, que servem de apoio para que os alunos tentem uma abordagem de tentativa e erro a partir do que foi entendido nos tópicos principais.
- iii. Texto teórico, permitindo conclusões finais sobre o material, mas esta deverá ser uma versão condensada quando comparada ao texto apresentado aos assimiladores.

### 5. Aspectos técnicos

O protótipo foi construído como uma composição de funções presentes nas bibliotecas Python, a fim de criar as funções para adaptação de conteúdo. Para acomodar os requisitos definidos para cada estilo de aprendizagem utilizamos os procedimentos apresentados na literatura, baseados nas seguintes técnicas:

- Extração de palavras-chave [Firoozeh et al. 2020], para tópicos principais e exemplos de perguntas.
- Extração de frase-chave [Firoozeh et al. 2020], principalmente para perguntas de exemplo.
- Sumarização [Gambhir and Gupta 2017], para textos teóricos e complementos.
- Funções Gerativas de Texto [Li et al. 2022], para questões teóricas e eventuais respostas para perguntas de exemplo.

O texto é pré-processado usando técnicas de processamento de linguagem natural. Esta ação cria conjuntos de palavras-chave e frases-chave que podem ser usadas para resumo, por exemplo. A partir de uma única entrada, são produzidas quatro versões adaptadas (arquivos de texto) de acordo com os modelos de aprendizagem de Kolb, organizadas na ordem apresentada na seção anterior. Deve-se ressaltar que o processo de geração de questões é, neste momento, realizado em execução separada utilizando transformadores desenvolvidos para esta tarefa específica [Santi et al. 2022].

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.

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.

Cada conjunto de técnica tem seus parâmetros pré-definidos para aplicação a cada estilo de aprendizagem, produzindo o texto resultante como uma apresentação ordenada de cada resultado das funções, seguindo o modelo de disposição definido na seção anterior. Para a sumarização extrativa, utilizou-se a combinação de técnicas do método 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, de acordo as preferências de cada estilo.

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.

Exceto pela geração de perguntas, todo o processo de adaptação dos estilos é totalmente automatizado e não envolve nenhuma participação do usuário. Porém, nesta versão inicial, a ferramenta é destinada ao uso dos instrutores, que inserem o conteúdo a ser transformado e recebem as versões adaptadas para seus alunos. O aluno que teve seu estilo de aprendizagem identificado após responder uma planilha com o questionário de Kolb pode selecionar o arquivo que contém o texto adequado ao seu estilo específico.

## **6. Resultados Obtidos**

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.

### **6.1. Sumarização do Texto**

A sumarização do texto é uma etapa crucial nesta proposta, onde 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.

Para exemplificar esse processo, será mostrado um tópico gerado especificamente para acomodadores a partir de um grande texto (em língua inglesa com quase 1300 palavras) sobre algoritmos genéticos. Ele foi gerado automaticamente a partir do texto original e é possível observar que resumir mantém apenas um assunto importante (100 palavras).

*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.*

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.

No contexto do modelo de Kolb, a técnica de sumarização busca identificar os tópicos principais do texto e apresentá-los de maneira correspondente a expectativa e preferência de cada aluno. Aplicando uma redução menor para os estilos que são adeptos da leitura e da reflexão sobre material escrito, e uma redução maior para aqueles estudantes de preferência mais ativa.

A ordem de apresentação e a estratégia de redução segue a proposta de adaptação da metodologia conforme demonstrado na seção 4. A técnica viabiliza a automação de parte principal do processo e atende ao requisitos conforme definição do modelos de trabalho.

## **6.2. Métodos extrativos**

Foram aplicadas técnicas de extração no contexto de palavras-chave e tópicos de cada texto, onde 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.

## **6.3. 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.

#### **6.4. Próximos Testes**

Ainda no contexto desta proposta, serão aplicados testes para verificação do funcionamento da integração com métodos generativos, avaliando o ganho alcançado pela entrada adicional fornecida por estes modelos.

Além disso, também é parte deste trabalho a realização de testes com voluntários para avaliar a percepção e o sentimento em relação a experiência de estudo com o texto adaptado.

### **7. 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.

As redes generativas estão em constante melhoria e serão cada vez mais parte da vida cotidiana 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. 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.

## 8. Conclusão

O ensino baseado na teoria dos estilos de aprendizagem tem sido controverso nos últimos anos. A maior parte das críticas vem do fato de que há poucas evidências sobre sua eficácia. Um argumento contra esta posição, que também defendemos, é que é difícil fornecer conteúdos distintos para estilos diferentes, prejudicando as experiências com estilos de aprendizagem.

Para resolver esse problema, propusemos uma ferramenta que utiliza técnicas de processamento de linguagem natural apoiadas por modernos algoritmos de aprendizado de máquina. O objetivo era gerar conteúdo personalizado e adaptado a estilos de aprendizagem específicos. O Modelo de Kolb foi escolhido como base de nossa ferramenta devido às suas características de aprendizagem bem definidas.

Os testes realizados para avaliar nossa ferramenta demonstraram que era viável gerar automaticamente conteúdo personalizado a partir de uma única fonte. Portanto, podemos concluir que o modelo proposto poderia produzir com sucesso conteúdos adaptados a cada um dos estilos de Kolb.

Esta ferramenta pode ser usada para melhorar um ITS não apenas para apresentar o conteúdo, mas também para ajudar o instrutor a criar versões adaptadas desse conteúdo.

## Referências

- Achiam, J., Adler, S., Agarwal, S., Ahmad, L., Akkaya, I., Aleman, F. L., Almeida, D., Altenschmidt, J., Altman, S., Anadkat, S., et al. (2023). Gpt-4 technical report. *arXiv preprint arXiv:2303.08774*.
- Brown, T. B., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., Askell, A., et al. (2020). Language models are few-shot learners. *arXiv preprint arXiv:2005.14165*.
- Coffield, F., Moseley, D., Hall, E., and Ecclestone, K. (2004). *Learning styles and pedagogy in post-16 learning: A systematic and critical review*. Learning & Skills Research Centre.
- Corbett, A. T., Koedinger, K. R., and Anderson, J. R. (1997). Intelligent tutoring systems. In *Handbook of human-computer interaction*, pages 849–874. Elsevier.
- Dunn, R. (1990). Rita dunn answers question on learning styles. *Educational Leadership*, 48(2):15–19.

- Felder, R. M., Silverman, L. K., et al. (1988). Learning and teaching styles in engineering education. *Engineering education*, 78(7):674–681.
- Firoozeh, N., Nazarenko, A., Alizon, F., and Daille, B. (2020). Keyword extraction: Issues and methods. *Natural Language Engineering*, 26(3):259–291.
- Gambhir, M. and Gupta, V. (2017). Recent automatic text summarization techniques: a survey. *Artificial Intelligence Review*, 47:1–66.
- Hämäläinen, W. and Vinni, M. (2006). Comparison of machine learning methods for intelligent tutoring systems. In *International Conference on Intelligent Tutoring Systems*, pages 525–534. Springer.
- Han, J., Zhao, W., Jiang, Q., Oubibi, M., and Hu, X. (2019). Intelligent tutoring system trends 2006-2018: A literature review. In *2019 Eighth International Conference on Educational Innovation through Technology (EITT)*, pages 153–159. IEEE.
- Idkhan, A. M. and Idris, M. M. (2021). Dimensions of students learning styles at the university with the kolb learning model. *International Journal of Environment, Engineering & Education*, 3(2):75–82.
- Janjanam, P. and Reddy, C. P. (2019). Text summarization: An essential study. In *2019 International Conference on Computational Intelligence in Data Science (ICCIDS)*, pages 1–6. IEEE.
- Kolb, D. A. (1976). Management and the learning process. *California management review*, 18(3):21–31.
- Kolb, D. A. (2007). *The Kolb learning style inventory*. Hay Resources Direct Boston, MA.
- Korkmaz, C. and Correia, A.-P. (2019). A review of research on machine learning in educational technology. *Educational Media International*, 56(3):250–267.
- Lavbič, D., Matek, T., and Zrnc, A. (2017). Recommender system for learning sql using hints. *Interactive Learning Environments*, 25(8):1048–1064.
- Li, J., Tang, T., Zhao, W. X., Nie, J.-Y., and Wen, J.-R. (2022). Pretrained language models for text generation: A survey. *arXiv preprint arXiv:2201.05273*.
- Mousavinasab, E., Zarifsanaiey, N., R. Niakan Kalhori, S., Rakhshan, M., Keikha, L., and Ghazi Saeedi, M. (2018). Intelligent tutoring systems: a systematic review of characteristics, applications, and evaluation methods. *Interactive Learning Environments*, pages 1–22.
- Nancekivell, S. E., Shah, P., and Gelman, S. A. (2020). Maybe they’re born with it, or maybe it’s experience: Toward a deeper understanding of the learning style myth. *Journal of Educational Psychology*, 112(2):221–235.
- Radford, A., Wu, J., Child, R., Luan, D., Amodei, D., and Sutskever, I. (2019). Language models are unsupervised multitask learners. *OpenAI Blog*, 1(8):9.
- Santi, M., Manacero, A., Peronaglio, F. F., Lobato, R. S., Spolon, R., and Cavenaghi, M. A. (2022). Training transformers for question generation task in intelligent tutoring systems. In *2022 17th Iberian Conference on Information Systems and Technologies (CISTI)*, pages 1–6.

- Sternberg, R. J. (1994). Allowing for thinking styles. *Educational leadership*, 52(3):36–40.
- Troussas, C., Krouska, A., and Virvou, M. (2019). Adaptive e-learning interactions using dynamic clustering of learners' characteristics. In *2019 10th International Conference on Information, Intelligence, Systems and Applications (IISA)*, pages 1–7.
- Wong, L.-H. and Looi, C.-K. (2012). Swarm intelligence: new techniques for adaptive systems to provide learning support. *Interactive Learning Environments*, 20(1):19–40.
- Zhang, Q., Guo, B., Wang, H., Liang, Y., Hao, S., and Yu, Z. (2019). Ai-powered text generation for harmonious human-machine interaction: Current state and future directions. In *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)*, pages 859–864. IEEE.
- Zhiping, L., Yu, S., and Tianwei, X. (2011). A formal model of personalized recommendation systems in intelligent tutoring systems. In *2011 6th International Conference on Computer Science & Education (ICCSE)*, pages 1006–1009. IEEE.