ReGeo ISSN: 2177-3246

ADAPTAÇÃO DE MATERIAL DIDÁTICO COM LLMS BASEADA EM ESTILOS DE APRENDIZAGEM DE FELDER-SILVERMAN

ADAPTATION OF EDUCATIONAL MATERIAL WITH LLMS BASED ON FELDER-SILVERMAN LEARNING STYLES

ADAPTACIÓN DE MATERIAL DIDÁCTICO CON LLMS BASADA EN LOS ESTILOS DE APRENDIZAJE DE FELDER-SILVERMAN

https://doi.org/10.56238/revgeov17n7-171

Data de submissão: 28/06/2026 **Data de publicação:** 28/07/2026

Kristiano Fernandes Plácido
Mestrando em Ciência da Computação
Instituição: Universidade Federal do Maranhão (UFMA)
Endereço: São Luís, Maranhão, Brasil
E-mail: kristiano.fernandes@discente.ufma.br
Orcid: 0009-0007-5980-9516
Lattes: https://lattes.cnpq.br/9506357581711231

Miriam Amanda Torres Lustosa
Doutorando em Ciência da Computação
Instituição: Universidade Federal do Maranhão (UFMA)
Endereço: São Luís, Maranhão, Brasil
E-mail: miriam.lustosa@discente.ufma.br
Orcid: 0009-0007-9314-620X
Lattes: http://lattes.cnpq.br/1215697776576647

Francisco Glaubos Nunes Clímaco
Doutor em Computação
Instituição: Universidade Federal do Maranhão (UFMA)
Endereço: São Luís, Maranhão, Brasil
E-mail: francisco.glaubos@ufma.br
Orcid: 0000-0002-1357-1318
Lattes: http://lattes.cnpq.br/1711180190759554

Tiago Bonini Borchartt
Doutor em Computação
Instituição: Universidade Federal do Maranhão (UFMA)
Endereço: São Luís, Maranhão, Brasil
E-mail: tiago.bonini@ufma.br
Orcid: 0000-0002-3709-8385
Lattes: http://lattes.cnpq.br/2352727269839328

RESUMO
Ambientes de Educação a Distância distribuem o mesmo material para todos os estudantes, ignorando diferenças cognitivas individuais. Este trabalho propõe e implementa uma metodologia automatizada de personalização de materiais didáticos baseado em Grandes Modelos de Linguagem (LLMs) e no modelo Felder-Silverman (FSLSM). O sistema cobre quatro fases: diagnóstico do perfil cognitivo via questionário reduzido de quatro questões, conversão do material em PDF para Markdown, seleção

interativa do escopo pelo estudante e reescrita adaptativa por LLM conforme o perfil identificado. O protótipo foi implementado em Python com a API Gemini. Testes com dois perfis opostos do FSLSM mostraram que o sistema produz materiais estruturalmente distintos a partir do mesmo conteúdo, alterando a arquitetura informacional do texto, não apenas o vocabulário.

Palavras-chave: Personalização de Aprendizagem. Estilos de Aprendizagem. Educação a Distância. Design Science Research.

ABSTRACT

Distance learning environments distribute the same material to all students, ignoring individual cognitive differences. This study proposes and implements an automated methodology for personalizing instructional materials based on Large Language Models (LLMs) and the Felder-Silverman model (FSLSM). The system consists of four phases: diagnosis of the cognitive profile via a short four-question questionnaire, conversion of PDF material to Markdown, interactive selection of the scope by the student, and adaptive rewriting by the LLM according to the identified profile. The prototype was implemented in Python using the Gemini API. Tests using two opposing FSLSM profiles showed that the system produces structurally distinct materials from the same content, altering the text's informational architecture—not just the vocabulary.

Keywords: Personalized Learning. Learning Styles. Distance Education. Design Science Research.

RESUMEN

Los entornos de educación a distancia distribuyen el mismo material a todos los estudiantes, sin tener en cuenta las diferencias cognitivas individuales. Este trabajo propone y aplica una metodología automatizada de personalización de materiales didácticos basada en los grandes modelos de lenguaje (LLM) y en el modelo de Felder-Silverman (FSLSM). El sistema abarca cuatro fases: diagnóstico del perfil cognitivo mediante un cuestionario reducido de cuatro preguntas, conversión del material de PDF a Markdown, selección interactiva del alcance por parte del estudiante y reescritura adaptativa mediante un LLM según el perfil identificado. El prototipo se ha implementado en Python con la API Gemini. Las pruebas realizadas con dos perfiles opuestos del FSLSM demostraron que el sistema genera materiales estructuralmente distintos a partir del mismo contenido, modificando la arquitectura informativa del texto, no solo el vocabulario.

Palabras clave: Personalización del Aprendizaje. Estilos de Aprendizaje. Educación a Distancia. Investigación en Diseño Científico.

1 INTRODUÇÃO

Sistemas de *e-learning* oferecem escala e flexibilidade, mas distribuem os mesmos materiais didáticos a todos os estudantes, ignorando diferenças cognitivas individuais (Spector *et al.*, 2020). Evidências consolidadas indicam que ajustar a abordagem pedagógica ao perfil de cada aluno melhora o engajamento, a retenção e o desempenho acadêmico (Bernacki; Greene; Lobczowski, 2021; Membrillo-Hernández *et al.*, 2024). O modelo mais utilizado para esse diagnóstico é o *Felder-Silverman Learning Style Model* (FSLSM) (Felder; Silverman, 1988), que classifica preferências cognitivas em quatro dimensões bipolares com implicações diretas sobre como estruturar o conteúdo didático, motivando sua adoção em sistemas adaptativos de aprendizagem (Troussas *et al.*, 2020).

O instrumento canônico do FSLSM, o *Index of Learning Styles* (ILS) (Felder; Spurlin, 2005), possui 44 questões, carga que provoca fadiga antes mesmo do início do estudo e classificações imprecisas, problema agravado em interfaces móveis. Pesquisas recentes demonstram que quatro questões representativas, combinadas com *ensemble learning* de pesos *fuzzy*, são suficientes para identificar estilos com alta acurácia (Troussas *et al.*, 2020), resultado convergente com abordagens híbridas de aprendizado profundo (Wani *et al.*, 2024). Do lado da adaptação, soluções baseadas em *Intelligent Tutoring Systems* (ITS) operam como sistemas reativos: recomendam materiais pré-existentes, mas não geram textos alinhados ao perfil cognitivo identificado (Sibley *et al.*, 2024). Os Grandes Modelos de Linguagem (LLMs) abrem uma nova perspectiva: em arquitetura multiagente, textos científicos de STEM foram reescritos conforme perfis FSLSM e estudantes preferiram significativamente os materiais personalizados em relação a versões genéricas (Zaghi; Vaccaro; Friday, 2025). Há, porém, uma lacuna na literatura: nenhum trabalho integra um diagnóstico facilitado de estilos com reescrita automática por LLM em um *pipeline* completo de personalização. Diante disso, este trabalho investiga a seguinte questão de pesquisa: é possível integrar o diagnóstico reduzido de estilos de aprendizagem à reescrita automática por LLMs em um *pipeline* completo que produza materiais estruturalmente adaptados ao perfil cognitivo do estudante?

Este trabalho propõe e implementa um artefato sob o paradigma da *Design Science Research* (DSR) (Pimentel; Filippo; Santoro, 2020): um *pipeline* de quatro fases que (i) classifica o estudante nas dimensões do FSLSM a partir de questionário reduzido, (ii) realiza a ingestão do material didático em PDF, (iii) permite a seleção interativa do escopo de estudo e (iv) produz, via LLM, uma versão adaptada conforme o perfil cognitivo mapeado. O protótipo foi implementado em Python com a API Gemini.

O restante deste artigo está organizado da seguinte forma: a Seção 2 discute o referencial teórico e os trabalhos relacionados; a Seção 3 descreve a metodologia e o artefato proposto; a Seção 4

apresenta os resultados preliminares obtidos; e a Seção 5 traz as conclusões e perspectivas de trabalhos futuros.

2 REFERENCIAL TEÓRICO

Esta seção organiza o referencial teórico em três eixos temáticos: identificação automática de estilos de aprendizagem; personalização de conteúdo educacional com aprendizado de máquina; e uso de Grandes Modelos de Linguagem na educação personalizada.

2.1 IDENTIFICAÇÃO AUTOMÁTICA DE ESTILOS DE APRENDIZAGEM

O modelo de Felder-Silverman (Felder; Silverman, 1988) é um dos mais utilizados para categorizar preferências cognitivas em ambientes tecnológicos de ensino. Seu instrumento canônico, o *Index of Learning Styles* (ILS) (Felder; Spurlin, 2005), possui 44 questões em quatro dimensões bipolares, impondo carga cognitiva significativa antes mesmo do início do estudo.

Troussas *et al.* (2020) apresentaram um questionário sintetizado, com quatro questões representativas do ILS, combinadas com *ensemble learning* de pesos *fuzzy* e dados demográficos e acadêmicos básicos; os autores mostraram que essa abordagem foi suficiente para identificar estilos com 94,44% de acurácia, superando classificadores individuais com fração do esforço do ILS completo. Este trabalho apoia-se diretamente nesse resultado para adotar o questionário reduzido. O mesmo padrão aparece em abordagens híbridas baseadas em *Transformer*/LSTM (Wani *et al.*, 2024) e em modelos orientados por trilhas de aprendizagem (Joseph *et al.*, 2024), reforçando a validade preditiva do FSLSM como base para sistemas adaptativos.

2.2 PERSONALIZAÇÃO DE CONTEÚDO COM APRENDIZADO DE MÁQUINA

Há evidências mensuráveis de que a personalização automatizada melhora o desempenho acadêmico. Modelos de aprendizado de máquina aplicados ao FSLSM produziram ganho médio de cinco pontos nas notas dos estudantes após intervenção personalizada, com aumento de engajamento (Villegas-Ch; García-Ortiz; Sánchez-Viteri, 2024).

Trabalhos sobre avaliação orientada por estilos em *blended learning* (Béres; Magyar; Turcsányi-Szabó, 2012) e planejamento de trilhas por grafos de conhecimento (Xiao *et al.*, 2024) reforçam que a curadoria interativa do escopo de estudo é necessária para que sistemas personalizados funcionem em escala, princípio que orienta o artefato proposto.

No contexto brasileiro, Peronaglio *et al.* (2023) apresentam uma proposta de adaptação automática por processamento de linguagem natural integrada a sistema tutor inteligente, mostrando a

viabilidade técnica em ambiente nacional, embora sem LLMs modernos, lacuna que o presente trabalho endereça diretamente.

2.3 GRANDES MODELOS DE LINGUAGEM NA EDUCAÇÃO PERSONALIZADA

A capacidade dos LLMs de personalizar textos educacionais para perfis cognitivos distintos foi demonstrada em um dos primeiros ensaios controlados randomizados sobre o tema. Zaghi, Vaccaro e Friday (2025) utilizaram o GPT-4 em arquitetura multiagente reescrevendo textos científicos de STEM conforme perfis FSLSM, e os estudantes do grupo experimental preferiram significativamente os materiais personalizados em relação a versões genéricas (teste de Mann-Whitney, $p = 0,059$).

Esse trabalho constitui a principal base empírica do presente trabalho. A maioria das implementações de LLMs em educação, porém, ainda não conecta diagnóstico formal de estilos à geração de conteúdo (Márquez-Carpintero; Lopez-Sellers; Cazorla, 2024), lacuna que este trabalho endereça. Evidências adicionais sobre geração de materiais sob demanda e interesse crescente pelo tema no Brasil aparecem em Li, Lee e Wu (2025), Rosa *et al.* (2025) e Jamil (2026).

3 METODOLOGIA

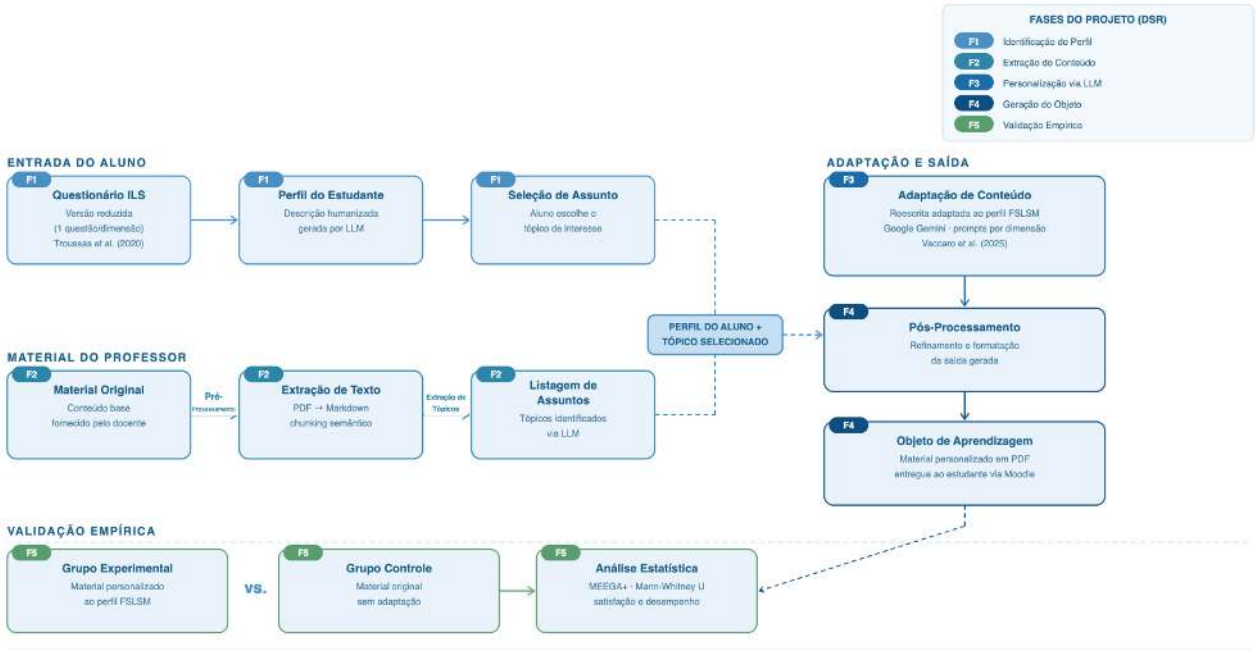
Esta pesquisa é de natureza aplicada, com abordagem qualitativa-quantitativa e finalidade explicativa, conduzida sob o paradigma da *Design Science Research* (DSR). Conforme sistematizado por Pimentel, Filippo e Santoro (2020) no contexto da Informática na Educação, a DSR é especialmente adequada quando o objetivo central do estudo é um artefato computacional. A escolha desse paradigma justifica-se porque o objeto central deste trabalho é um *pipeline* automatizado de personalização de material didático apoiado por Grandes Modelos de Linguagem (LLMs), desenvolvido para responder a um problema concreto e socialmente relevante: a sobrecarga cognitiva imposta pelo *Index of Learning Styles* (ILS) de Felder e Silverman (Felder; Silverman, 1988; Felder; Spurlin, 2005) em sua forma completa (44 itens) e a ausência de mecanismos que adaptem o conteúdo automaticamente ao perfil cognitivo identificado. A Figura 1 apresenta o fluxo geral da solução.

O trabalho organiza-se em três momentos iterativos, alinhados aos ciclos da DSR:

a) o *ciclo de relevância*, no qual o problema é delimitado a partir das demandas do ensino adaptativo e da literatura recente sobre identificação de estilos de aprendizagem com perguntas reduzidas (Goda *et al.*, 2020; Troussas *et al.*, 2020; Wani *et al.*, 2024);
b) o *ciclo de rigor*, no qual o artefato se apoia no modelo de Felder e Silverman (1988), no *ensemble learning* com pesos *fuzzy* proposto por Troussas *et al.* (2020) e nas evidências sobre reescrita didática por LLMs apresentadas por Zaghi, Vaccaro e Friday (2025); e

c) o *ciclo de design*, no qual o artefato é construído, refinado e avaliado.

Figura 1. Fluxo do sistema de personalização de materiais didáticos.



Fonte: Elaborada pelos autores (2026).

3.1 CARACTERIZAÇÃO DO ARTEFATO PROPOSTO

O artefato é um sistema que recebe dois tipos de entrada: o material didático bruto do professor (em formato .pdf) e as respostas do estudante a um questionário reduzido de diagnóstico de estilo de aprendizagem. A saída é um material personalizado de acordo com as dimensões cognitivas mapeadas para aquele estudante segundo o modelo de Felder e Silverman (Felder; Silverman, 1988). O sistema opera em quatro fases sequenciais, descritas a seguir.

3.2 FASE 1: DIAGNÓSTICO OTIMIZADO DO PERFIL DE APRENDIZAGEM

O objetivo desta fase é mapear o perfil cognitivo do estudante com a menor carga inicial possível. Em vez das 44 questões originais do *Index of Learning Styles* (Felder; Spurlin, 2005), adota-se um questionário reduzido de quatro perguntas, uma por dimensão do FSLSM, fundamentado em resultados que demonstram ser possível identificar estilos de aprendizagem com *ensemble learning* de pesos *fuzzy* atingindo alta acurácia com fração do esforço do ILS completo (Troussas *et al.*, 2020). Essa viabilidade é reforçada por abordagens híbridas para identificação de estilos em ambientes de *e-learning*, que confirmam que diagnósticos enxutos são suficientes para orientar a adaptação instrucional (Rasheed; Wahid, 2024).

Concluída a classificação, o sistema armazena o perfil do estudante nas quatro dimensões

(ativo/reflexivo, sensorial/intuitivo, visual/verbal e sequencial/global) para uso em todas as interações subsequentes. Em consonância com Felder e Silverman (1988), o estilo de aprendizagem é tratado como vetor de preferências dinâmicas, não como rótulo fixo.

3.3 FASE 2: INGESTÃO E PROCESSAMENTO DO MATERIAL DIDÁTICO

Nesta fase, o professor realiza o *upload* do material em .pdf. O sistema, implementado em Python, usa a biblioteca *PyMuPDF4LLM* para extrair o texto, preservando a ordem lógica do conteúdo e descartando artefatos de diagramação sem relevância semântica. O texto extraído é convertido para *Markdown* (.md), formato escolhido por sua leveza sintática, legibilidade humana e, principalmente, pela estrutura hierárquica (cabeçalhos, listas e blocos de código) que favorece o raciocínio contextual de modelos de linguagem de grande porte sem o ruído de marcação de HTML ou a rigidez de LaTeX.

Esta fase funciona como pré-processamento canônico: ao homogeneizar a representação de entrada, o sistema pode processar materiais de fontes diversas, como apostilas, artigos e capítulos de livros. Essa necessidade de ingestão unificada de conteúdos heterogêneos é um requisito recorrente em soluções adaptativas baseadas em IA, cujos *pipelines* precisam converter arquivos de aula, gravações, leituras e outros recursos em uma representação computacionalmente uniforme antes de qualquer processo de personalização (Sajja *et al.*, 2024; Zaghi; Vaccaro; Friday, 2025).

3.4 FASE 3: SELEÇÃO DO CONTEÚDO

Esta fase coloca o estudante como agente ativo na seleção do escopo de estudo. Um LLM recebe o arquivo *Markdown* produzido na fase anterior e gera uma lista estruturada dos tópicos e subtópicos presentes no material. Essa lista é exibida na interface da aplicação, e o estudante escolhe explicitamente qual assunto quer estudar.

Com a escolha feita, o sistema delimita semanticamente o escopo do material original, produzindo um novo *Markdown* com apenas o conteúdo do tópico selecionado. Essa etapa cumpre duas funções simultâneas: respeita a autonomia do aprendiz e reduz o contexto fornecido ao modelo na fase seguinte, diminuindo custo computacional e evitando problemas de janela de contexto.

3.5 FASE 4: GERAÇÃO DO MATERIAL DIDÁTICO ADAPTADO

Na quarta fase ocorre a personalização propriamente dita. O LLM recebe dois insumos simultaneamente:

a) o *Markdown* com o escopo selecionado (Seção 3.4);

b) o vetor de estilos de aprendizagem obtido na Fase 1 (Seção 3.2).

Com isso, o modelo reescreve e reorganiza o conteúdo de acordo com as preferências cognitivas identificadas, conforme o mapeamento apresentado na Tabela 1.

Tabela 1. Mapeamento das dimensões do modelo Felder-Silverman para estratégias de reescrita do LLM.

Dimensão	Polo A	Polo B
Processamento	Ativo (exemplos, exercícios práticos)	Reflexivo (análise, síntese conceitual)
Percepção	Sensorial (concreto, aplicado)	Intuitivo (abstrato, teórico)
Entrada	Visual (*prompts* descritivos)	Verbal (texto linear, narrativo)
Organização	Sequencial (passo a passo, incremental)	Global (visão sistêmica, panorâmica)

Fonte: Elaborada pelos autores (2026).

A viabilidade técnica de arquiteturas multiagente com LLMs para personalização de textos científicos em STEM foi demonstrada em ensaio controlado randomizado, com preferência significativa dos estudantes pelos materiais personalizados em relação a versões genéricas (Zaghi; Vaccaro; Friday, 2025), fundamentando diretamente a abordagem desta fase. Resultados complementares mostram que intervenções automatizadas por LLMs impactam positivamente a revisão textual, a motivação e as emoções dos estudantes, reforçando o potencial dessas ferramentas em contextos educacionais (Meyer *et al.*, 2023).

Para a dimensão que contenha "visual/verbal", o sistema não gera imagens automaticamente. O LLM produz *prompts* descritivos que podem ser utilizados em etapa posterior para geração das imagens. Essa decisão de *design* reflete a cautela recomendada diante das limitações de confiabilidade de conteúdo gerado por modelos de linguagem para fins didáticos (Kasneci *et al.*, 2023): no mesmo domínio, a opção por imagens pré-geradas estáticas mostrou-se mais adequada do que a geração automática individualizada (Zaghi; Vaccaro; Friday, 2025), tema retomado na discussão das limitações do trabalho.

3.6 PROCEDIMENTOS METODOLÓGICOS E CICLO DE AVALIAÇÃO

A pesquisa articula cinco etapas aos ciclos da DSR. As três primeiras cobrem a construção do artefato: revisão sistemática da literatura sobre estilos de aprendizagem e LLMs em educação, especificação de requisitos a partir das lacunas identificadas, e projeto e implementação do *pipeline* em arquitetura modular. As duas etapas seguintes voltam-se à avaliação: verificação técnica por execuções controladas com materiais de diferentes domínios, com inspeção qualitativa conduzida por dois avaliadores independentes quanto à fidelidade temática e à coerência com o perfil-alvo; e

avaliação empírica com usuários reais por meio do instrumento MEEGA+ (Petri; Von Wangenheim; Borgatto, 2019), adaptado ao contexto investigado.

Conforme previsto pelo Ciclo de Engenharia da DSR (Pimentel; Filippo; Santoro, 2020), os resultados de cada etapa realimentam o refinamento do artefato, especialmente na engenharia de *prompts* das Fases 3 e 4 e na calibração do questionário reduzido da Fase 1.

4 RESULTADOS PRELIMINARES

Como esta pesquisa adota o paradigma da *Design Science Research* (DSR), os resultados preliminares concentram-se em demonstrar a viabilidade técnica inicial do artefato proposto (fase de *design* e desenvolvimento) e em estabelecer o protocolo para a sua avaliação empírica futura.

As informações subsequentes delineiam o status atual da execução do *pipeline*, os esforços experimentais iniciais empregando modelos de linguagem grande (LLMs) e a estrutura metodológica estabelecida para validação com usuários reais.

4.1 ESTADO ATUAL DA IMPLEMENTAÇÃO

Até o presente momento, o ciclo de desenvolvimento do artefato concentrou-se na integração das Fases 1, 2, 3 e 4 da arquitetura proposta (detalhada na Figura 1). O módulo de ingestão foi implementado em Python, utilizando a biblioteca *PyMuPDF4LLM* para a extração do texto bruto de arquivos .pdf e sua conversão estruturada para *Markdown* (.md).

A segmentação interativa do conteúdo (Fase 3) também encontra-se funcional. Testes preliminares demonstraram que a representação em *Markdown* reduz significativamente as alucinações do LLM no momento de isolar tópicos, uma vez que a hierarquia de cabeçalhos (como # e ##) fornece âncoras semânticas para o modelo delimitar o escopo antes da etapa de personalização. O questionário reduzido da Fase 1 está atualmente em fase de calibração empírica.

4.2 ENGENHARIA DE PROMPTS

A engenharia de *prompts* constitui um componente central do artefato: é ela que traduz o conhecimento pedagógico do modelo FSLSM em instruções operacionais para o LLM. O sistema utiliza dois *prompts* especializados: um para a Fase 3 (segmentação do conteúdo) e outro para a Fase 4 (reescrita adaptada), cujas decisões de *design* são detalhadas a seguir.

Ambos os *prompts* adotam a arquitetura de duas mensagens definida pelas APIs de modelos de linguagem: uma mensagem de *sistema* (system) e uma mensagem de *usuário* (user). Essa separação não é apenas técnica; ela reflete uma distinção conceitual fundamental para o funcionamento robusto

do sistema.

O bloco [SYSTEM] contém as regras fixas de comportamento do modelo: o papel que ele deve assumir, as restrições que deve respeitar e a lógica de adaptação pedagógica. Esse bloco atua como o motor metodológico e permanece idêntico entre execuções. O bloco [USER], por sua vez, atua como a camada de dados variáveis: recebe o perfil cognitivo do estudante, o tópico selecionado e o trecho do material original a ser processado.

Essa separação traz consequências práticas relevantes. O comportamento do modelo torna-se controlável e auditável, pois qualquer alteração na lógica de adaptação ocorre em um único local, o bloco [SYSTEM], mitigando riscos de inconsistências entre execuções. A substituição do modelo fundacional preserva a lógica pedagógica estruturada, demandando, no máximo, ajustes sintáticos no texto do *prompt* (*prompt tuning*), sem necessidade de refatoração do sistema. Além disso, a separação facilita o refinamento iterativo ao longo dos ciclos de avaliação da DSR (Pimentel; Filippo; Santoro, 2020), permitindo que variáveis de contexto e regras pedagógicas sejam ajustadas e avaliadas de forma independente.

4.3 PROMPT DE LISTAGEM DE TÓPICOS (FASE 3)

O primeiro *prompt* é responsável por extrair a estrutura temática do material e devolvê-la em formato estruturado. Qualquer instrução adicional (resumir, explicar, reformular) introduz ruído semântico que compromete o conteúdo original nas fases seguintes. Esta restrição adotada no *design* é fundamental para garantir a integridade do conteúdo.

Duas decisões de *design* merecem destaque. A primeira é o uso de JSON como formato de saída: o JSON é processável de forma determinística pela interface, independentemente de variações estilísticas entre modelos ou versões, o que não ocorre com texto livre. A segunda é a instrução explícita de não acrescentar informações externas; sem essa restrição, modelos de linguagem tendem a enriquecer a lista com tópicos inferidos do contexto mas ausentes no material, comportamento indesejável num sistema cujo objetivo é personalizar *o conteúdo do professor*, não substituí-lo. O Quadro 1 apresenta sua estrutura completa.

4.4 PROMPT DE PERSONALIZAÇÃO DO MATERIAL (FASE 4)

O segundo *prompt* é o núcleo pedagógico do sistema. Ele recebe simultaneamente o perfil cognitivo do estudante nas quatro dimensões do FSLSM e o trecho do material selecionado na Fase 3, e instrui o LLM a reescrever o conteúdo, ajustando sua estrutura, linguagem e elementos didáticos ao perfil mapeado.

Tem-se três decisões de *design* centrais nesse *prompt*. A primeira é o tratamento independente por dimensão, em que cada uma das quatro dimensões do FSLSM recebe um bloco de instrução próprio, com as regras para cada polo descritas separadamente. Isso torna o *prompt* adaptável para qualquer uma das 16 combinações de perfil possíveis sem precisar enumerá-las (Troussas *et al.*, 2020).

Quadro 1. Prompt 1 da Fase 3 — listagem de tópicos do material.

```
[SYSTEM]
  Você é um especialista em organização de conteúdo de disciplinas universitárias. Seu trabalho é ler
     uma amostra de um material em Markdown e propor possíveis assuntos/tópicos principais dessa
     disciplina.
     IMPORTANTE: responda ESTRITAMENTE em JSON válido, sem comentários,
     sem texto antes ou depois. O formato deve ser:
     [
      {\n"
        \"id\": 1,\n'
        \"titulo\": \"Título curto do assunto\",\n'
        \"descricao\": \"Breve descrição do que é abordado\",\n'
        \"palavras_chave\": [\"palavra1\", \"palavra2\"]\n'
      }

     ]

[USER]
  A seguir está uma amostra do conteúdo de uma disciplina.
     Com base nessa amostra, identifique de 3 a 8 possíveis assuntos/tópicos principais da disciplina.
     Use palavras–chave que provavelmente aparecem no texto para ajudar a localizar o assunto
     depois.
     AMOSTRA DO CONTEUDO: {texto_amostra}
```

Fonte: Elaborado pelos autores (2026).

A segunda é a especificação do que *não* fazer em cada polo, além do que fazer. Por exemplo, para o polo intuitivo, o *prompt* não apenas diz "priorize conceitos e teorias", mas também instrui "reduza exemplos repetitivos". Essa negação explícita é necessária porque LLMs tendem a acumular elementos de diferentes estilos quando não há restrição ativa, produzindo textos que tentam agradar a todos os perfis ao mesmo tempo e não se adequam plenamente a nenhum.

Quadro 2. Prompt 2 da Fase 4 — reescrita adaptada ao perfil FSLSM.

```
[SYSTEM]
#Role: Especialista em Design Instrucional e Teoria de Felder–Silverman
    ##Contexto
    Sou um professor universitário e preciso adaptar um conteúdo técnico para um aluno com um
    perfil de aprendizagem específico, baseado no Index of Learning Styles (ILS).
    ##Instruções de Adaptação (Diretrizes Teóricas)
    Utilize as seguintes restrições baseadas nos polos de Felder e Silverman:
    1. **Eixo de Percepção:**
    – Se **Sensorial**: Foque em aplicações práticas, exemplos do mundo real e dados concretos.
    EVITE digressões teóricas longas ou abstrações sem aplicação clara.
    – Se **Intuitivo**: Priorize a teoria subjacente, modelos matemáticos e a inovação conceitual.
    REDUZA exemplos práticos repetitivos e explicações procedimentais óbvias.
    2. **Eixo de Entrada:**
    – Se **Visual**: Ao longo do texto, identifique os pontos onde uma representação visual
    ajudaria e insira blocos de sugestão no formato exato abaixo:
    [SUGESTAO_IMAGEM: <prompt em inglês detalhado: inicie citando a área de estudo (ex:
    Computer Science), depois descreva visualmente o diagrama usando formas simples, vetores e
    estrutura do conceito. Peça um design sem textos longos (textless)>]
    Insira esses blocos em momentos estratégicos. EVITE blocos de texto excessivamente densos
    sem nenhum respiro ou sugestão visual.
    – Se **Verbal**: Utilize explicações textuais detalhadas, analogias narrativas e discussões teó
    ricas. NÃO dependa de recursos visuais ou esquemas para passar a mensagem central.
    3. **Eixo de Processamento:**
    – Se **Ativo**: Insira uma atividade de \"mão na massa\" ou um desafio imediato para o aluno
    testar. EVITE passividade e leitura ininterrupta.
    – Se **Reflexivo**: Insira perguntas instigantes que exijam reflexão e pausa interpretativa longa
    antes de prosseguir. EVITE forçar o aluno a tomar ações práticas imediatas.
    4. **Eixo de Compreensão:**
    – Se **Sequencial**: Apresente o conteúdo em uma trilha linear, passo a passo, garantindo que
    cada etapa dependa da anterior. EVITE pular etapas ou apresentar a conclusão antes do raciocí
    nio base.
    – Se **Global**: Comece apresentando o objetivo macro e a utilidade final do conceito antes de
    mergulhar nos detalhes. EVITE começar direto por partes isoladas sem mostrar o cenário geral (a
     \"big picture\").
    ##Formato de Saída
    Gere o conteúdo estruturado em Markdown. Use blocos de código para exemplos técnicos e fó
    rmulas matemáticas em texto simples ou notação Markdown padrão (ex: ‘O(n^2)‘ ou ‘2^n‘).
)
[USER]
Dados do Aluno (Perfil FSLSM)
    **Processamento:** {dimensoes['processamento']}
    **Percepção:** {dimensoes['percepcao']}
    **Entrada:** {dimensoes['entrada']}
    **Compreensão:** {dimensoes['compreensao']}
    Conteúdo a ser Adaptado
    TEMA ESCOLHIDO: {assunto}
    INFORMACAO ORIGINAL RETIRADA DA APOSTILA:{texto[:8000]}
```

Fonte: Elaborado pelos autores (2026).

A terceira é o bloco de regras obrigatórias, que impõe preservação do conteúdo factual e reduz a invenção de dados, ou seja, "alucinação". Em contextos educacionais, a precisão do conteúdo é inegociável (Márquez-Carpintero; Lopez-Sellers; Cazorla, 2024): um LLM que reescreve livremente pode alterar fórmulas, datas ou definições de forma imperceptível, comprometendo o aprendizado. O Quadro 2 apresenta a estrutura completa do *prompt*.

Para validar a premissa da Fase 4, foi selecionado o conteúdo integral do Bloco 1 da disciplina de Matemática Discreta e Lógica do curso de Computação e Inteligência Artificial da UFMA, abrangendo os fundamentos da lógica proposicional, proposições simples e compostas, conectivos lógicos, tabelas-verdade, tautologia e contradição.

O material foi submetido ao sistema duas vezes, simulando dois perfis diametralmente opostos segundo o FSLSM: {Global, Sensorial, Visual, Reflexivo} e {Sequencial, Sensorial, Verbal, Reflexivo}. A escolha desses dois perfis é deliberada: ambos compartilham a dimensão {Sensorial, Reflexivo}, isolando o efeito das dimensões que diferem — Global *versus* Sequencial e Visual *versus* Verbal —, deixando a comparação mais precisa e interpretável.

Os resultados evidenciam diferenças estruturais e discursivas entre as saídas geradas. O material adaptado para o perfil *Global* apresentou uma visão panorâmica do conceito antes de detalhar os casos particulares, enquanto a versão *Sequencial* organizou o conteúdo em passos incrementais e ordenados. De modo análogo, a saída para o perfil *Visual* privilegiou representações gráficas e diagramas, ao passo que a versão *Verbal* recorreu a texto corrido, definições formais e exemplos discursivos. A Tabela 2 sintetiza as principais diferenças observadas entre os dois perfis para esse trecho.

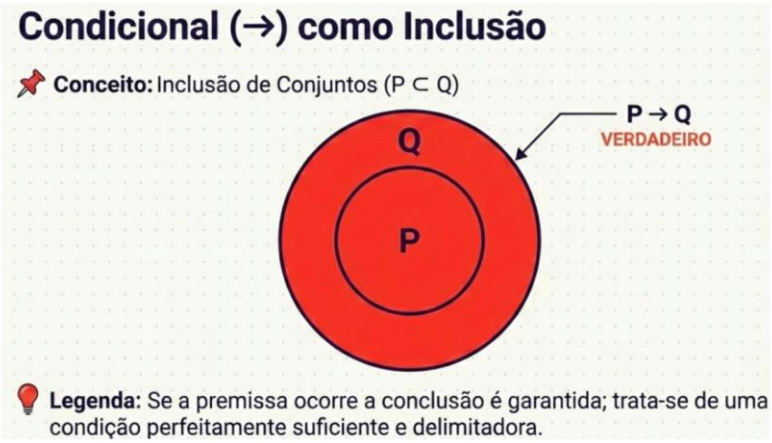
Tabela 2. Comparação das saídas geradas para os dois perfis diferentes.

Dimensão	**Perfil A — {Global, Visual, Sensorial, Reflexivo}**	**Perfil B — {Sequencial, Verbal, Sensorial, Reflexivo}**
Abertura	Contextualiza o conectivo no cotidiano antes de formalizá-lo.	Define a estrutura imediatamente: *"Sentenças condicionais seguem a estrutura 'Se uma coisa acontece, então outra coisa acontece'."*
Organização	Panorama primeiro: exemplos cotidianos → metáfora da "promessa" → tabela-verdade.	Progressão linear e nomeada: definição → **Regra Principal** (em negrito) → tabela-verdade.

Elemento didático	**Caixa de Reflexão** ao final, para sedimentação após a exposição completa.	**Pergunta aplicada** logo após a tabela: *"Em qual situação o professor não teria cumprido a sua palavra?"*
Elementos visuais	Diagrama de conjuntos concêntricos (P ⊂ Q) integrado ao texto (ver Figura 2).	Sem figura. Mesmo conceito transmitido em prosa: *"o grupo p está incluído dentro do grupo q"*.
Registro linguístico	Narrativo e conversacional; frases retóricas (*"Estranho, não é?"*); analogias cotidianas.	Estruturado por subseções nomeadas; linguagem direta e funcional; sem ornamentos retóricos.
Análise da tabela-verdade	Prosa contínua retomando a metáfora da promessa em cada linha.	Marcadores explícitos por linha (**2ª linha (V→F):** [...]); único caso falso destacado em negrito.

Fonte: Elaborada pelos autores (2026).

Figura 2. Diagrama de conjuntos gerado para o Perfil A.



Fonte: Elaborada pelos autores (2026).

Os resultados evidenciam que a diferenciação produzida pelo sistema vai além de uma simples substituição de vocabulário. O modelo alterou a *arquitetura informacional* do texto: a ordem de apresentação dos conceitos mudou (panorama antes dos detalhes no Perfil A, *Global/Visual*; definição antes do exemplo no Perfil B, *Sequencial/Verbal*), o tipo de elemento didático inserido mudou (caixa de reflexão ao final *versus* pergunta aplicada intercalada), e o registro linguístico mudou (narrativo e conversacional *versus* estruturado e funcional). Tais achados sugerem que o sistema é capaz de gerar adaptações pedagogicamente coerentes com os princípios do modelo Felder-Silverman, produzindo materiais estruturalmente distintos a partir de um mesmo conteúdo de entrada.

5 CONCLUSÃO

Este trabalho apresentou uma metodologia para personalização automática de materiais didáticos baseada em LLMs e no modelo de estilos de aprendizagem de Felder e Silverman (1988), voltada a contextos de Educação a Distância. O problema que a motiva é conhecido: sistemas de *e-learning* oferecem escala, mas os materiais continuam iguais para todos os estudantes, independentemente de suas diferenças cognitivas (Spector *et al.*, 2020; Zaghi; Vaccaro; Friday, 2025).

O artefato proposto é um *pipeline* de quatro fases: diagnóstico do perfil de aprendizagem via questionário reduzido (Troussas *et al.*, 2020), ingestão e processamento do material em PDF, curadoria interativa do escopo de estudo e geração do objeto de aprendizagem adaptado por LLM. O protótipo foi implementado em Python com a API Gemini e está operacional nas Fases 2, 3 e 4. A Fase 1 está em calibração empírica.

A prova de conceito da Seção 4 mostrou que o sistema produz materiais estruturalmente distintos a partir do mesmo conteúdo de entrada. Para o bloco de lógica proposicional de Matemática Discreta, o perfil *Global/Visual* recebeu visão panorâmica com elementos gráficos e caixa de reflexão; o perfil *Sequencial/Verbal* foi atendido com progressão linear, definições formais e perguntas intercaladas. A diferenciação não ficou na superfície do vocabulário: o modelo alterou a arquitetura informacional do texto.

A fim de consolidar a validação da metodologia, os trabalhos futuros organizam-se em duas frentes. A primeira será a avaliação empírica com usuários reais, em que os participantes avaliarão a experiência por meio do instrumento MEEGA+ (Petri; Von Wangenheim; Borgatto, 2019), adaptado ao contexto desta pesquisa; o desenho experimental seguirá a lógica do ensaio controlado de Zaghi, Vaccaro e Friday (2025), comparando a recepção da versão personalizada em relação à versão genérica do mesmo conteúdo. A segunda frente será a calibração empírica do questionário reduzido, tomando como parâmetro a acurácia de 94,44% obtida por Troussas *et al.* (2020) com quatro questões e *ensemble learning* de pesos *fuzzy*, bem como o processo de validação de inventários de forma curta descrito por Goda *et al.* (2020).

REFERÊNCIAS

BÉRES, I.; MAGYAR, T.; TURCSÁNYI-SZABÓ, M. Towards a personalised, learning style based collaborative blended learning model with individual assessment. **Informatics in Education**, v. 11, n. 1, p. 1-28, 2012.

BERNACKI, M. L.; GREENE, M. J.; LOBCZOWSKI, N. G. A systematic review of research on personalized learning: personalized by whom, to what, how, and for what purpose(s)? **Educational Psychology Review**, v. 33, n. 4, p. 1627-1659, 2021.

FELDER, R. M.; SILVERMAN, L. K. Learning and teaching styles in engineering education. **Engineering Education**, v. 78, n. 7, p. 674-681, 1988.

FELDER, R. M.; SPURLIN, J. Applications, reliability and validity of the Index of Learning Styles. **International Journal of Continuing Engineering Education and Life-Long Learning**, v. 21, n. 1, p. 103-112, 2005.

GODA, Y. *et al.* Development of a short-form learning style inventory for automated driving safety education. *In*: **IEEE INTERNATIONAL CONFERENCE ON TEACHING, ASSESSMENT, AND LEARNING FOR ENGINEERING (TALE)**, 2020, on-line. Anais. [S. l.]: IEEE, 2020. p. 847-851.

JAMIL, H. M. Human–AI co-orchestration in data science education: interactive, adaptive, and personalized lecture design for diverse learners. **Education and Information Technologies**, 2026.

JOSEPH, L. *et al.* Exploring the effectiveness of learning path recommendation based on Felder-Silverman learning style model: a learning analytics intervention approach. **Education and Information Technologies**, 2024.

KASNECI, E. *et al.* ChatGPT for good? On opportunities and challenges of large language models for education. **Learning and Individual Differences**, v. 103, p. 102274, 2023.

LI, C.; LEE, X.; WU, X. Provide personalized programming learning for individuals based on large language models. **Education and Information Technologies**, 2025.

MÁRQUEZ-CARPINTERO, L.; LOPEZ-SELLERS, A.; CAZORLA, M. Simulation of teaching behaviours in intelligent tutoring systems: a review using large language models. **Education and Information Technologies**, 2024.

MEMBRILLO-HERNÁNDEZ, J. *et al.* Using an adaptive learning tool to improve student performance and satisfaction in online and face-to-face education for a more personalized approach. **Smart Learning Environments**, v. 11, n. 1, p. 6, 2024.

MEYER, J. *et al.* Using LLMs to bring evidence-based feedback into the classroom: AI-generated feedback increases secondary students' text revision, motivation, and positive emotions. **Computers and Education: Artificial Intelligence**, v. 6, p. 100199, 2023.

PERONAGLIO, F. F. *et al.* Adaptação automática de conteúdo aplicada em ambiente interativo de aprendizagem individualizada. **Revista Brasileira de Informática na Educação**, v. 31, p. 255-270, 2023.

PETRI, G.; VON WANGENHEIM, C. G.; BORGATTO, A. F. MEEGA+: um modelo para a avaliação de jogos educacionais para o ensino de computação. **Revista Brasileira de Informática na Educação**, v. 27, n. 3, p. 52-81, 2019. [CONFIRMAR TÍTULO NA FONTE ORIGINAL]

PIMENTEL, M.; FILIPPO, D.; SANTORO, F. M. Design Science Research: fazendo pesquisas científicas rigorosas atreladas ao desenvolvimento de artefatos computacionais projetados para a educação. *In*: JAQUES, P. A. *et al.* (org.). **Metodologia de pesquisa científica em informática na educação**: concepção de pesquisa. Porto Alegre: SBC, 2020. v. 1, cap. 5. [CONFIRMAR TÍTULO DO CAPÍTULO NA FONTE ORIGINAL]

RASHEED, F.; WAHID, A. Automatic identification of learning styles using multi-layer topic modeling. **Information**, v. 15, n. 5, p. 277, 2024.

ROSA, Y. S. *et al.* Reflexões sobre o uso de LLMs no ensino de programação. *In*: **SIMPÓSIO BRASILEIRO DE EDUCAÇÃO EM COMPUTAÇÃO (EDUCOMP)**, 2025, Juiz de Fora. Anais. Porto Alegre: SBC, 2025. p. 1-10.

SAJJA, R. *et al.* Artificial intelligence-enabled intelligent assistant for personalized and adaptive learning in higher education. **Information**, v. 15, n. 10, p. 596, 2024.

SIBLEY, L. *et al.* Feasibility of adaptive teaching with technology: which implementation conditions matter? **Computers & Education**, v. 219, p. 105108, 2024.

SPECTOR, J. M. *et al.* A systematic literature review of personalized learning terms. **Smart Learning Environments**, v. 7, n. 1, p. 33, 2020.

TROUSSAS, C. *et al.* Ensemble learning using fuzzy weights to improve learning style identification for adapted instructional routines. **Entropy**, v. 22, n. 7, p. 735, 2020.

VILLEGAS-CH, W.; GARCÍA-ORTIZ, J.; SÁNCHEZ-VITERI, S. Personalization of learning: machine learning models for adapting educational content to individual learning styles. **Future Internet**, 2024. [CONFIRMAR PERIÓDICO, VOLUME E PÁGINAS — DOI CADASTRADO APONTA PARA IEEE ACCESS]

WANI, M. A. *et al.* Enhancing e-learning adaptability with automated learning style identification and sentiment analysis: a hybrid deep learning approach for smart education. **Information**, v. 15, n. 5, 2024.

XIAO, Q. *et al.* Sustainable personalized e-learning through integrated cross-course learning path planning. **Sustainability**, v. 16, p. 8867, 2024.

ZAGHI, A.; VACCARO, M. Jr.; FRIDAY, M. Multi-agentic LLMs for personalizing STEM texts. **Applied Sciences**, v. 15, n. 13, p. 7579, 2025.