

Empatia Cognitiva Artificial: Como o GPT Reflete e Adapta Estilos de Raciocínio em Contextos Educacionais

Andréia dos Santos Sachete, Instituto Federal de Educação, Ciência e Tecnologia Farroupilha (IFFar) – Campus de Alegrete, andreia.sachete@iffarroupilha.edu.br, <https://orcid.org/0000-0003-2226-3322>

Alba Valéria de Sant'Anna de Freitas Loiola, Instituto Federal de Educação, Ciência e Tecnologia de Santa Catarina (IFSC) – Campus de Caçador, alba.valeria@ifsc.edu.br, <https://orcid.org/0000-0003-2418-3393>

Fábio Diniz Rossi, Instituto Federal de Educação, Ciência e Tecnologia Farroupilha (IFFar) – Campus de Alegrete, fabio.rossi@iffarroupilha.edu.br, <https://orcid.org/0000-0002-2450-1024>

Resumo. *Este artigo investiga como o GPT-5 manifesta diferentes padrões discursivos ao atuar em tarefas educacionais e em que medida esses padrões se aproximam de estilos de raciocínio descritos na literatura sobre estilos cognitivos e de aprendizagem. Foram analisadas respostas produzidas para quarenta tarefas educacionais, executadas em três configurações de temperatura, parâmetro que controla o grau de aleatoriedade na seleção das palavras geradas pelo modelo, totalizando 120 interações. A metodologia combinou indicadores linguísticos, embeddings semânticos, medidas de similaridade e técnicas de agrupamento. Os resultados evidenciaram quatro padrões discursivos predominantes. Temperaturas mais baixas favoreceram respostas estruturadas e analíticas, enquanto valores mais elevados ampliaram a diversidade lexical e a presença de características narrativas. Mais do que confirmar que a temperatura altera o texto gerado, o estudo mostra que sua variação produz mudanças sistemáticas e mensuráveis na coerência, na complexidade sintática e na organização discursiva, permitindo associar diferentes configurações probabilísticas a formas distintas de apresentação do raciocínio. Os resultados contribuem para a compreensão do GPT-5 como potencial mediador adaptativo em ambientes educacionais, embora a adequação desses estilos a estudantes reais ainda deva ser investigada.*

Palavras-chave: *Inteligência Artificial, Educação, Modelos de Linguagem, Estilos Cognitivos, Tutoria Adaptativa, GPT-5.*

Artificial Cognitive Empathy: How GPT Reflects and Adapts Reasoning Styles in Educational Contexts

Abstract. *This article investigates how GPT-5 exhibits different discursive patterns when performing educational tasks and the extent to which these patterns resemble reasoning styles described in the literature on cognitive and learning styles. Responses generated for forty educational tasks were analyzed under three temperature settings, a parameter that controls the degree of randomness in the selection of words generated by the model, totaling 120 interactions. The methodology combined linguistic indicators, semantic embeddings, similarity measures, and clustering techniques. The results revealed four predominant discursive patterns. Lower temperatures favored structured and analytical responses, whereas higher values increased lexical diversity and the presence of narrative features. Beyond confirming that temperature alters the generated text, the*

study demonstrates that its variation produces systematic and measurable changes in coherence, syntactic complexity, and discursive organization, making it possible to associate different probabilistic configurations with distinct ways of presenting reasoning. The findings contribute to understanding GPT-5 as a potential adaptive mediator in educational environments, although the suitability of these styles for real students still needs to be investigated.

Keywords: Artificial Intelligence, Education, Large Language Models, Cognitive Styles, Adaptive Tutoring, GPT-5.

1. Introdução

O avanço recente da Inteligência Artificial (IA) tem promovido transformações expressivas na educação, especialmente a partir da consolidação dos Grandes Modelos de Linguagem (*Large Language Models* - LLMs) como mediadores do processo de aprendizagem. Esses modelos, representados por arquiteturas como o GPT-5¹, integram compreensão contextual, geração textual e adaptação a diferentes perfis de usuários, configurando novas formas de tutoria, *feedback* e personalização da aprendizagem. No contexto educacional, essa evolução inaugura um paradigma dialógico, em que o conhecimento é construído por meio da interação entre o estudante e a máquina, ultrapassando a lógica instrucional tradicional e incorporando dimensões discursivas, cognitivas e afetivas do aprendizado. Assim, os LLMs atuam como agentes de linguagem capazes de explicar, argumentar, sintetizar e refletir, funções que, quando inseridas em ambientes de tutoria inteligente, ampliam as possibilidades de acompanhamento individualizado e personalização cognitiva (Sachete *et al.*, 2025; Minaee *et al.*, 2024).

Apesar desses avanços, persiste um desafio epistemológico em compreender se os LLMs apenas reproduzem padrões estatísticos de linguagem ou se são capazes de manifestar estilos de raciocínio distintos, comparáveis aos modos humanos de pensar e aprender. Parte-se da hipótese de que os LLMs não produzem respostas neutras, mas expressam configurações discursivas associadas a estilos cognitivos específicos, que emergem de acordo com o contexto e com os parâmetros de geração. Essa variação pode influenciar diretamente a qualidade da tutoria, uma vez que o modo de raciocínio simulado pela IA pode alinhar-se ou entrar em dissonância com o estilo de aprendizagem do estudante, afetando engajamento, clareza e empatia cognitiva.

Nesse cenário, propõe-se o conceito de *espelho cognitivo* como eixo interpretativo da investigação (Ramachandiran *et al.*, 2025). A metáfora sugere que os LLMs, ao processarem e gerarem linguagem, não apenas organizam padrões sintáticos e semânticos, mas projetam, de forma probabilística, estruturas de raciocínio análogas às humanas. Tal como um espelho que reflete formas sem possuir consciência delas, o modelo reproduz modos de pensar internalizados em seus parâmetros de treinamento, evidenciando analogias entre o raciocínio algorítmico e o pensamento conceitual. Assim, o estudo dos LLMs, enquanto espelhos cognitivos, permite compreender a emergência de estilos discursivos como manifestações simuladas de processos humanos de aprendizagem e reflexão.

¹ <https://openai.com/pt-BR/index/introducing-gpt-5/>



O objetivo geral deste trabalho é investigar de que maneira o GPT-5 manifesta estilos de raciocínio distintos durante a execução de tarefas educacionais e de que modo se relacionam com perfis cognitivos humanos. Especificamente, busca-se: (i) identificar padrões linguísticos e semânticos que caracterizam diferentes modos de raciocínio simulados pela IA; (ii) classificar esses padrões com base em indicadores de coerência, densidade lexical e estrutura discursiva; e (iii) analisar a correspondência entre o estilo cognitivo predominante da IA e o perfil de aprendizagem dos estudantes, considerando seus efeitos sobre engajamento e percepção da interação. Com base nesses objetivos, este estudo contribui para o campo da tutoria inteligente ao propor uma abordagem centrada na noção de espelho cognitivo, segundo a qual a IA reflete e ajusta seu modo de raciocínio conforme o interlocutor humano, promovendo uma interação cognitivamente empática e adaptativa.

O trabalho está dividido em quatro Seções: a Seção 2 apresenta os fundamentos teóricos sobre estilos de aprendizagem, cognição e o papel dos LLMs na educação; a Seção 3 descreve os procedimentos metodológicos e analíticos; a Seção 4 expõe e discute os principais achados; e a Seção 5 reúne as conclusões e indica perspectivas futuras sobre adaptação cognitiva em tutores baseados em IA.

2. Fundamentação Teórica

A fundamentação teórica desta pesquisa integra os conceitos de estilos de aprendizagem, cognição e linguagem, articulando-os aos avanços do Processamento de Linguagem Natural (PLN) e dos Grandes Modelos de Linguagem aplicados à educação (Loiola *et al.*, 2024). Essa abordagem interdisciplinar combina aportes da psicologia educacional e da inteligência artificial, permitindo compreender como a produção linguística mediada por algoritmos pode expressar diferentes modos de raciocínio e sustentar formas de personalização cognitiva.

A compreensão das diferenças cognitivas entre aprendizes constitui o ponto de partida para a personalização do ensino. Kolb (Kolb, 1984) concebe o aprendizado como um processo experiencial em que a vivência se transforma em conhecimento por meio de ciclos de percepção, reflexão e ação. Essa perspectiva originou a tipologia dos estilos de aprendizagem divergente, assimilador, convergente e acomodador, que expressam distintas formas de apreensão e organização do saber. Em continuidade, Alonso, Gallego e Honey (Alonso; Gallego e Honey, 1994) desenvolveram o modelo CHAEA (*Cuestionario Honey-Alonso de Estilos de Aprendizaje*), que identifica quatro perfis cognitivos predominantes (ativo, reflexivo, teórico e pragmático), ressaltando que cada indivíduo combina essas dimensões em proporções variáveis. O modelo Felder-Silverman (Graf *et al.*, 2007) ampliou essa compreensão ao introduzir dimensões opostas (ativa e reflexiva, sensorial e intuitiva, visual e verbal, sequencial e global) evidenciando a diversidade de preferências cognitivas e suas manifestações linguísticas.

A literatura não apresenta consenso sobre a definição dos conceitos de Estilos Cognitivos (EC) e Estilos de Aprendizagem (EA). Enquanto alguns autores os tratam como sinônimos, outros estabelecem distinções quanto à natureza e à função de cada um. Almeida (Almeida, 2010) diferencia ambos ao afirmar que os EC dizem respeito ao controle e à organização dos processos cognitivos, enquanto os EA se relacionam ao controle e à organização das estratégias utilizadas na aprendizagem e na aquisição de informações. Há também pesquisadores que consideram os EA uma subcategoria dos EC, originando o termo Estilos Cognitivos de Aprendizagem (ECA), entendido como a forma

individual e recorrente com que o estudante organiza e representa novas informações durante o processo de aprendizagem (Riding e Rayner, 2000). A integração entre esses construtos permite compreender as diferenças individuais no processamento do conhecimento e fundamentar práticas pedagógicas personalizadas.

Essas teorias clássicas oferecem sustentação para a identificação dos estilos de raciocínio observados neste estudo (analítico, narrativo, sintético e reflexivo) que emergem tanto da observação de comportamentos humanos quanto da análise dos padrões discursivos gerados por modelos de linguagem. O estilo analítico caracteriza-se pela estrutura lógica e uso de conectivos causais; o narrativo distingue-se pela construção sequencial e presença de metáforas; o sintético evidencia objetividade e concisão; e o reflexivo apresenta abstração e marcas metacognitivas. Quando manifestados nas produções textuais de LLMs, esses estilos configuram simulações de diferentes modos de pensar, traduzindo padrões cognitivos em formas discursivas.

A emergência desses comportamentos está diretamente associada aos fundamentos do PLN, área da Inteligência Artificial dedicada a capacitar sistemas computacionais a compreender, interpretar e gerar textos em linguagem natural (Zhang e Kim, 2023). O advento das arquiteturas baseadas em Transformers (Bader e Alhijawi, 2025) revolucionou o campo ao permitir a criação de modelos de larga escala com bilhões de parâmetros, capazes de captar nuances sintáticas, semânticas e pragmáticas (Minaee *et al.*, 2024). Esses modelos não apenas processam o conteúdo textual, mas também reproduzem estruturas argumentativas e padrões discursivos internalizados a partir de vastos corpora linguísticos. Em contextos educacionais, tais capacidades possibilitam aplicações voltadas à geração de *feedback*, explicações conceituais e tutoria adaptativa, inaugurando um novo paradigma de interação entre estudantes e sistemas inteligentes (Sachete *et al.*, 2025).

Entre os parâmetros que modulam o comportamento discursivo dos LLMs destaca-se a temperatura, responsável por ajustar o grau de aleatoriedade na geração de tokens (Castilho e Gurevych, 2011). Valores baixos (próximas de zero) produzem respostas mais determinísticas e analíticas, enquanto temperaturas elevadas (próximas de 2) ampliam a diversidade lexical e introduzem traços de criatividade e narratividade, ainda que com menor coerência global (Holtzman *et al.*, 2020). A relação entre estrutura textual e entropia evidencia a correspondência entre linguagem e pensamento, uma ideia amplamente discutida na linguística cognitiva, segundo a qual a linguagem não apenas expressa, mas também estrutura processos cognitivos (Langacker, 1987; Dancygier, 2017). Nesse sentido, as variações discursivas dos modelos de linguagem podem ser compreendidas como simulações probabilísticas de raciocínios humanos, emergentes da interação entre padrões linguísticos aprendidos e mecanismos estocásticos de geração. Essa concepção teórica sustenta a noção de espelho cognitivo apresentada na introdução, entendida aqui como uma metáfora interpretativa que descreve a capacidade dos LLMs de refletir e modular estilos de raciocínio a partir de regularidades estatísticas internalizadas.

A literatura sobre tutoria inteligente oferece o enquadramento pedagógico que contextualiza esse fenômeno. Desde os primeiros sistemas baseados em regras até os tutores adaptativos contemporâneos, o objetivo tem sido aproximar a mediação computacional dos processos de ensino humano. O *feedback* personalizado favorece o desempenho e a motivação dos estudantes, embora mesmo os sistemas mais avançados

ainda apresentem limitações quanto à adaptação estilística, isto é, à capacidade de ajustar não apenas o conteúdo, mas também o modo de raciocínio e o tom discursivo em função do perfil de aprendizagem de cada usuário. É justamente nesse ponto que a integração dos LLMs aos sistemas de tutoria representa um avanço ao possibilitar a personalização cognitiva, entendida como a adaptação dinâmica do raciocínio e da linguagem do modelo ao estilo de aprendizagem individual (Paulino *et al.*, 2022).

Apesar desses avanços, a literatura ainda carece de estudos que investiguem de forma empírica como os LLMs expressam diferentes estilos cognitivos e de que modo essas variações influenciam o engajamento e a aprendizagem dos estudantes. A maioria das pesquisas privilegia aspectos técnicos, como coerência textual e acurácia semântica, em detrimento das dimensões cognitivas e afetivas da interação humano-máquina (Sachete *et al.*, 2025; Minaee *et al.*, 2024). A ausência de diretrizes para a calibração de parâmetros de geração em contextos pedagógicos reforça a necessidade de abordagens integradas que articulem forma discursiva, perfil de aprendizagem e impacto educacional. Nesse sentido, o presente estudo busca preencher essa lacuna ao examinar o GPT-5 como agente tutor capaz de simular e ajustar estilos de raciocínio, contribuindo para a consolidação de uma inteligência artificial educacional mais transparente, empática e adaptativa.

3. Metodologia

A metodologia deste estudo fundamenta-se em uma abordagem quantitativa de análise linguística automatizada, orientada à identificação dos estilos de raciocínio simulados pelo modelo GPT-5 e à investigação dos efeitos das variações nos parâmetros de geração, especialmente a temperatura, sobre a diversidade lexical, a coerência global e o estilo discursivo. Essa estratégia permite mensurar padrões linguísticos e semânticos com rigor empírico, assegurando reprodutibilidade e consistência aos resultados.

O experimento foi conduzido em um ambiente controlado de tutoria digital, no qual o GPT-5 atuou como agente instrucional em interações simuladas de ensino-aprendizagem. Foram elaboradas quarenta tarefas educacionais (*prompts*) representando situações típicas de aprendizagem, distribuídas em quatro categorias principais: interpretação de textos, argumentação sobre temas sociais, explicação de conceitos técnicos e resolução de problemas aplicados. Cada categoria foi escolhida de modo a contemplar diferentes demandas cognitivas, permitindo observar variações discursivas associadas a contextos explicativos, argumentativos e reflexivos.

Exemplos dessas tarefas incluem “*Explique o significado simbólico do texto a seguir...*”, “*Você concorda com a afirmação abaixo? Justifique com base em evidências...*”, “*Descreva, em linguagem simples, o funcionamento de um sistema de IA supervisionada*” e “*Diante do seguinte cenário, como o estudante poderia aplicar o conceito de aprendizado adaptativo?*”. Cada tarefa foi submetida ao modelo em três configurações de temperatura, totalizando 120 respostas analisadas. Essa variação teve o propósito de examinar de que modo diferentes níveis de entropia influenciam a estrutura linguística, a complexidade sintática e a expressividade textual. As saídas geradas em *temperatura* = 0 apresentaram comportamento mais determinístico e analítico, enquanto *temperatura* = 1 promoveu equilíbrio entre precisão e criatividade. Já em *temperatura* = 2, observou-se maior diversidade lexical e expansão narrativa, acompanhadas de leve redução da coerência textual. Todas as condições experimentais de rede e hardware foram



mantidas fixas, garantindo comparabilidade entre as execuções, conforme as recomendações metodológicas de (Sachete *et al.*, 2025).

A análise quantitativa das respostas foi realizada por meio de métricas linguísticas e semânticas, incluindo índices de diversidade lexical, densidade de conectivos causais, comprimento médio das sentenças e similaridade vetorial entre *embeddings*. As métricas foram calculadas de forma automatizada, permitindo avaliar com precisão a relação entre temperatura e variação discursiva. Em seguida, os resultados foram submetidos à técnica de redução dimensional t-SNE, com o objetivo de visualizar padrões de agrupamento entre os diferentes estilos de raciocínio identificados. Essa combinação de procedimentos quantitativos e de representação vetorial permitiu uma caracterização robusta dos comportamentos linguísticos emergentes no GPT-5, associando variações formais da linguagem a traços cognitivos simulados.

Para assegurar a confiabilidade dos dados, todas as execuções foram replicadas em três rodadas independentes, minimizando o impacto de variações aleatórias no processo de geração. As respostas foram armazenadas e processadas em ambiente isolado, garantindo rastreabilidade e reprodutibilidade. O delineamento experimental adotado, portanto, segue o princípio de controle das variáveis externas e de padronização dos parâmetros, permitindo que as diferenças observadas sejam atribuídas exclusivamente às mudanças de temperatura e não a fatores externos de interferência. Por fim, os resultados dessa análise quantitativa fornecem a base empírica para a discussão apresentada na seção seguinte, na qual se examinam os estilos de raciocínio predominantes e suas implicações cognitivas e educacionais. Essa estrutura metodológica, ao articular precisão técnica e relevância pedagógica, permite compreender como o comportamento linguístico do GPT-5 pode refletir distintos modos de raciocínio, sustentando a hipótese de uma simulação cognitiva probabilística mediada por linguagem.

4. Resultados e Discussão

A análise automatizada das respostas foi realizada por meio de vetorização semântica utilizando o modelo *text-embedding-3-large*², que representa as relações semânticas entre palavras e sentenças em um espaço multidimensional. Em seguida, aplicaram-se medidas de similaridade de cosseno (*cosine similarity*) para mensurar a proximidade conceitual entre as respostas, conforme metodologia de (Reimers e Gurevych, 2019). Além dessas medidas, foram extraídos quatro indicadores linguísticos centrais. Os quatro indicadores utilizados não correspondem a uma escala previamente validada em sua forma conjunta. Eles foram definidos pelos autores como uma operacionalização exploratória dos padrões discursivos investigados, com base em propriedades linguísticas associadas à organização textual, à variedade lexical, à elaboração sintática e à presença de marcas metacognitivas: (i) coerência global, medida pela similaridade média entre sentenças consecutivas; (ii) densidade lexical, calculada pela razão entre palavras de conteúdo e o total de palavras; (iii) complexidade sintática, expressa pelo número médio de orações subordinadas por sentença; e (iv) metacognição, definida pela frequência relativa de expressões autorreferenciais, como “penso que”, “significa que” e “portanto”. Esses indicadores forneceram uma caracterização quantitativa detalhada do comportamento discursivo do modelo, permitindo identificar padrões associados aos quatro estilos de raciocínio considerados neste estudo: analítico,

² <https://platform.openai.com/docs/models/text-embedding-3-large>



narrativo, sintético e reflexivo. A associação entre esses indicadores e os estilos analítico, narrativo, sintético e reflexivo foi realizada como uma interpretação teórica dos agrupamentos, considerando as características predominantes de cada grupo. Assim, os estilos não foram tratados como diagnósticos cognitivos, mas como rótulos interpretativos atribuídos a padrões linguísticos observados nas respostas.

A clusterização dos *embeddings* foi realizada por meio do algoritmo *K-Means* (Dehariya; Shrivastava e Jain, 2010), com $k = 4^3$, resultando em agrupamentos semanticamente coerentes e compatíveis com as categorias teóricas previamente definidas. A distribuição percentual dos estilos em função da temperatura é apresentada na Tabela 1 evidenciando a predominância do raciocínio analítico em *temperatura* = 0 ($T = 0$), do reflexivo em níveis intermediários e do narrativo em *temperatura* = 2 ($T = 2$). A correlação entre temperatura e diversidade lexical foi estimada em $r = 0.78$, indicando que níveis moderados de entropia ampliam a complexidade semântica sem comprometer a coerência textual.

Tabela 1. Distribuição dos estilos de raciocínio por temperatura.

Temperatura (T)	Analítico	Narrativo	Sintético	Reflexivo
0	48%	12%	25%	15%
1	15%	44%	16%	25%
2	8%	55%	12%	25%

Com base nesses resultados, foram calculadas as médias dos principais indicadores linguísticos em cada configuração de temperatura, conforme a Tabela 2. Observa-se que, à medida que a temperatura aumenta, a diversidade lexical cresce de forma consistente, enquanto a coerência global tende a decrescer, refletindo o impacto da aleatoriedade na estrutura textual. A complexidade sintática também se eleva, sugerindo maior elaboração discursiva em condições de alta entropia.

Tabela 2. Métricas linguísticas por temperatura (média).

Temperatura (T)	Diversidade Lexical	Coerência Global	Complexidade Sintática
0	0.42	0.88	1.10
1	0.68	0.82	1.25
2	0.74	0.75	1.32

Para fins de visualização, foram gerados quatro gráficos representativos das análises quantitativas. As Figuras 1-4 sintetizam os resultados principais: a projeção t-SNE (*t-Distributed Stochastic Neighbor Embedding*) dos *embeddings*, evidenciando a separação dos quatro estilos de raciocínio; a distribuição percentual dos estilos por

³ O valor $k=4$ foi definido a priori, com base na expectativa teórica de quatro padrões discursivos. Reconhece-se que essa escolha pode introduzir viés de confirmação, uma vez que restringe previamente o número de agrupamentos. Portanto, os clusters devem ser interpretados como uma classificação exploratória teoricamente orientada, e não como demonstração de que os dados possuem necessariamente quatro estruturas naturais.

temperatura; a relação entre diversidade lexical e temperatura; e a variação da coerência global conforme o aumento da entropia. As visualizações reforçam o comportamento progressivo do modelo, em que níveis intermediários de temperatura produzem equilíbrio entre estrutura e criatividade textual.

A análise quantitativa das respostas geradas pelo GPT-5 permitiu identificar padrões consistentes de variação linguística e semântica em função dos parâmetros de geração, especialmente da temperatura. A projeção t-SNE dos *embeddings*, representada na Figura 1 revelou quatro agrupamentos semanticamente distintos e bem definidos, correspondentes aos estilos de raciocínio identificados. Essa separação vetorial confirma que as diferenças observadas entre as respostas não se restringem à superfície lexical, mas refletem variações estruturais e conceituais na organização do discurso. O estilo analítico apresentou alta coerência semântica e uso frequente de conectivos causais, enquanto o estilo narrativo destacou-se por sequências descritivas e expressões figurativas. O raciocínio sintético mostrou maior concisão e objetividade, e o reflexivo, maior presença de expressões metacognitivas e abstração linguística.




Figura 1. Projeção t-SNE por estilo.

Os efeitos da temperatura sobre a distribuição desses estilos são apresentados na Tabela 1 e na Figura 2. Em configurações determinísticas ($T = 0$), o modelo produziu predominantemente respostas analíticas, caracterizadas por estrutura linear e uso controlado de conectivos. À medida que a temperatura aumentou para $T = 1$, observou-se uma diversificação dos estilos, com crescimento expressivo das ocorrências reflexivas e narrativas, associadas ao equilíbrio entre criatividade e coerência. Em $T = 2$, o modelo passou a exibir maior proporção de textos narrativos e menor regularidade sintática, refletindo um aumento da fluidez lexical e da aleatoriedade discursiva. Essa tendência demonstra que a entropia atua como modulador do estilo de raciocínio simulado, deslocando o comportamento do modelo de uma postura lógica e analítica para uma produção mais expressiva e imaginativa.




Figura 2. Distribuição por temperatura.

Os indicadores linguísticos médios de diversidade lexical, coerência global e complexidade sintática, apresentados na Tabela 2 e visualizados nas Figuras 3 e 4, reforçam essa dinâmica. Observa-se crescimento progressivo da diversidade lexical entre $T = 0$ e $T = 2$, acompanhada de ligeira redução da coerência global, o que confirma que níveis intermediários de temperatura promovem o ponto ótimo entre precisão e criatividade.




Figura 3. Diversidade lexical vs. temperatura.

A correlação entre temperatura e diversidade lexical ($r = 0.78$) indica que a variação do parâmetro contribui significativamente para o aumento da complexidade semântica das respostas, sem comprometimento substancial da estrutura discursiva. Já a complexidade sintática apresenta tendência ascendente com o aumento da temperatura, sugerindo que o modelo, em condições de maior entropia, recorre a estruturas frasais mais longas e subordinadas, possivelmente em decorrência de maior liberdade composicional.

Esses resultados demonstram que o GPT-5 não apenas ajusta o conteúdo de suas respostas de acordo com o contexto, mas também modula seu modo de raciocínio textual em função de parâmetros probabilísticos. O modelo mostra-se capaz de simular diferentes formas de organização cognitiva, variando entre raciocínios lógicos, narrativos, sintéticos e reflexivos, o que reforça a hipótese de que os LLMs podem atuar como espelhos cognitivos em nível discursivo.




Figura 4. Coerência global vs. temperatura.

Embora tais simulações não representem processos mentais humanos, elas configuram padrões linguísticos análogos aos estilos de aprendizagem descritos por (Kolb, 1984) e (Alonso; Gallego e Honey, 1994), oferecendo evidências empíricas de que a parametrização adequada do modelo pode favorecer determinadas formas de expressão cognitiva. A análise dos dados também sugere que o comportamento do GPT-5 tende a se estabilizar em torno de $T = 1$, ponto em que a diversidade lexical e a coerência textual alcançam equilíbrio. Essa condição pode ser interpretada como uma “zona de convergência cognitiva” do modelo, na qual há coexistência de precisão conceitual e flexibilidade discursiva. Em aplicações educacionais, essa configuração se mostra particularmente promissora, pois possibilita a geração de respostas suficientemente estruturadas para apoiar a aprendizagem, mas também adaptáveis o bastante para promover engajamento e contextualização.

As evidências empíricas apresentadas demonstram que o comportamento discursivo do GPT-5 pode ser descrito em termos de variação contínua ao longo de um eixo cognitivo, no qual o aumento de entropia desloca o raciocínio da IA do polo analítico para o polo narrativo. Essa gradação estilística, observada de forma consistente nas métricas e visualizações, corrobora a hipótese de que a configuração probabilística dos LLMs é determinante para a expressão de estilos de raciocínio simulados. Em síntese, o modelo se comporta como um sistema adaptativo de linguagem, cuja forma de raciocínio emerge da interação entre arquitetura, dados de treinamento e parâmetros de geração. Dessa forma, os resultados sustentam a tese de que os LLMs, ao operar em regimes de entropia controlada, exibem padrões de raciocínio análogos aos estilos cognitivos humanos descritos na literatura educacional. A análise quantitativa conduzida permite afirmar que o GPT-5 manifesta comportamentos discursivos diferenciados e previsíveis, que podem ser explorados pedagogicamente para calibrar o grau de estrutura ou criatividade exigido em tarefas educacionais. Essa constatação reforça o potencial dos modelos de linguagem como instrumentos de apoio à tutoria adaptativa, nos quais a personalização não depende apenas do conteúdo transmitido, mas também da forma cognitiva com que a informação é expressa.

5. Conclusões e Trabalhos Futuros

A presente pesquisa analisou empiricamente a manifestação de estilos de raciocínio simulados pelo modelo GPT-5 em um contexto educacional, com foco na



identificação de padrões linguísticos e semânticos emergentes sob diferentes configurações de temperatura. Os resultados evidenciaram que o parâmetro de temperatura influencia diretamente a modulação do estilo discursivo do modelo. Configurações determinísticas ($T = 0$) resultaram em produções analíticas, caracterizadas por alta coerência e estrutura linear; valores intermediários ($T = 1$) promoveram equilíbrio entre precisão e criatividade, favorecendo respostas reflexivas; e temperaturas mais elevadas ($T = 2$) estimularam maior diversidade lexical e traços narrativos, ainda que com redução moderada da coerência global. A correlação positiva ($r = 0.78$) entre temperatura e diversidade lexical infere uma tendência descritiva de aumento da diversidade lexical com a elevação da temperatura.

Essas evidências apontam para um novo horizonte de aplicação pedagógica dos LLMs, em que a personalização da tutoria pode ser alcançada por meio da calibragem de parâmetros linguísticos, ajustando o estilo cognitivo da IA ao tipo de tarefa educacional. Ao invés de tratar a geração textual apenas como um meio de comunicação, este estudo propõe compreendê-la como uma variável cognitiva, ou um canal pelo qual o modelo expressa diferentes modos de pensamento. Dessa forma, o GPT-5 se comporta como um sistema adaptativo de linguagem, cuja plasticidade estilística pode ser explorada para modular o grau de estrutura ou criatividade exigido em contextos de ensino.

Embora os resultados tenham revelado padrões robustos, algumas limitações devem ser reconhecidas. O estudo concentrou-se exclusivamente no modelo GPT-5, não abrangendo comparações com outros modelos, que poderiam apresentar dinâmicas distintas de variação estilística. Ademais, o GPT-5 é um modelo proprietário, cujos pesos, dados completos de treinamento e detalhes internos de arquitetura não são publicamente acessíveis. Além disso, o corpus experimental foi composto por um conjunto fixo de quarenta tarefas e respostas textuais, o que delimita o escopo da generalização. Pesquisas futuras poderão ampliar o número de tarefas, diversificar os domínios temáticos e incorporar novas métricas de desempenho educacional.

Referências

- Almeida, K. R. d. Descrição e análise de diferentes estilos de aprendizagem. *Revista Interlocução*, Belo Horizonte, v. 3, n. 3, p. 38–49, 2010.
- Alonso, C. M.; Gallego, D. J.; Honey, P. *Los estilos de aprendizaje: procedimientos de diagnóstico y mejora*. Bilbao: Ediciones Mensajero, 1994.
- Bader, A.; Alhijawi, B. Transformer-based approach for detecting llm-generated scientific text. In: *2025 International Conference on New Trends in Computing Sciences (ICTCS)*. [S.l.: s.n.], 2025. p. 26–31.
- Castilho, R. E. de; Gurevych, I. Semantic service retrieval based on natural language querying and semantic similarity. In: *2011 IEEE Fifth International Conference on Semantic Computing*. [S.l.: s.n.], 2011. p. 173–176.
- Dancygier, B. (ed.). *The Cambridge Handbook of Cognitive Linguistics*. Cambridge: Cambridge University Press, 2017.
- Dehariya, V. K.; Shrivastava, S. K.; Jain, R. Clustering of image data set using k-means and fuzzy k-means algorithms. In: *2010 International Conference on Computational Intelligence and Communication Networks*. [S.l.: s.n.], 2010. p. 386–391.



- Graf, S.; Viola, S. R.; Leo, T.; Kinshuk. In-depth analysis of the felder-silverman learning style dimensions. *Journal of Research on Technology in Education*, Routledge, v. 40, n. 1, p. 79–93, 2007. Disponível em: <https://doi.org/10.1080/15391523.2007.10782498>.
- Holtzman, A.; Buys, J.; Du, L.; Forbes, M.; Choi, Y. The curious case of neural text degeneration. In: *International Conference on Learning Representations (ICLR)*. [s.n.], 2020. Disponível em: <https://arxiv.org/abs/1904.09751>.
- Kolb, D. A. *Experiential Learning: Experience as the Source of Learning and Development*. Englewood Cliffs, NJ: Prentice Hall, 1984.
- Langacker, R. W. *Foundations of Cognitive Grammar: Theoretical Prerequisites*. Stanford: Stanford University Press, 1987.
- Loiola, A.; Sachete, A. S.; Gomes, R. S.; Grandi, R. H. Ia generativa em competências discursivas na educação básica. *Revista Eletrônica de Educação*, v. 18, n. 1, p. e6680122, out. 2024. Disponível em: <https://www.reveduc.ufscar.br/index.php/reveduc/article/view/6680>.
- Minaee, S. et al. Large language models: A survey. *ArXiv*, abs/2402.06196, 2024. Disponível em: <https://api.semanticscholar.org/CorpusID:267617032>.
- Paulino, D.; Correia, A.; Guimarães, D.; Barroso, J.; Paredes, H. Uncovering the potential of cognitive personalization for ui adaptation in crowd work. In: *2022 IEEE 25th International Conference on Computer Supported Cooperative Work in Design (CSCWD)*. [S.l.: s.n.], 2022. p. 484–489.
- Ramachandiran, C. R. et al. Intelligent cognitive mirroring model to enhance learning experience in autistic spectrum disorder children in malaysia. In: *2025 6th International Conference on Information Technology and Education Technology (ITET)*. [S.l.: s.n.], 2025. p. 96–101.
- Reimers, N.; Gurevych, I. Sentence-bert: Sentence embeddings using siamese bert-networks. In: *Association for Computational Linguistics. Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing*. 2019. p. 3982–3992. Disponível em: <https://aclanthology.org/D19-1410/>.
- Riding, R.; Rayner, S. *Cognitive Styles and Learning Strategies: Understanding Style Differences in Learning and Behavior*. London: David Fulton Publishers, 2000.
- Sachete, A. S.; Loiola, A. V. d. S. d. F.; Rossi, F. D.; Gomes, R. S. Voce se torna responsável por aquilo que gera: análise semântica e temporal de modelos de linguagem. *Revista Novas Tecnologias na Educação (RENTE)*, v. 23, n. 1, p. 345–356, 2025. Disponível em: <https://seer.ufrgs.br/renote>.
- Zhang, N.; Kim, J. A survey on attention mechanism in nlp. In: *2023 International Conference on Electronics, Information, and Communication (ICEIC)*. [S.l.: s.n.], 2023. p. 1–4.