

SAMANTHA: IA APLICADA AO ESTUDO DA RELAÇÃO ENTRE ATENÇÃO E APRENDIZAGEM

SAMANTHA: AI APPLIED TO THE STUDY OF THE RELATIONSHIP BETWEEN ATTENTION AND LEARNING

 <https://orcid.org/0009-0007-8995-1492> Elias Souza Ribeiro^A
 <https://orcid.org/0000-0002-5248-7733> Carlos Eduardo Batista de Sousa^B

^A Universidade Estadual do Norte Fluminense Darcy Ribeiro (UENF), Campos dos Goytacazes, RJ, Brasil

^B Universidade Estadual do Norte Fluminense Darcy Ribeiro (UENF), Campos dos Goytacazes, RJ, Brasil

Recebido em: 31 de julho de 2024 | **Aceito em:** 02 de dezembro de 2024

Correspondência: Elias Souza Ribeiro (eliasribeiro85@yahoo.com.br)

Resumo

Este estudo apresenta uma Inteligência Artificial (IA) generativa chamada Samantha, desenvolvida para investigar a relação entre atenção e aprendizado. A pesquisa foca na capacidade da atenção de prever conflitos educacionais e desempenho em sala de aula. Foi criada uma aplicação psicométrica chamada iGnosi, que classifica a atenção em quatro categorias: Concentrada, Alerta, Dividida e Alternada. Dados psicométricos foram coletados de 144 alunos de graduação. Para o desenvolvimento da Samantha, utilizou-se o modelo base GPT-3.5 turbo 125, treinado com um *dataset* contendo 577 entradas para três papéis: *System*, *User* e *Assistant*. O treinamento envolveu 307.266 *tokens* em 3 *epochs*, resultando em uma perda de treinamento de 0,0318. Nos testes iniciais, Samantha demonstrou habilidade em interpretar e orientar pesquisadores e docentes com base nos resultados, mostrando-se inspiradora e motivadora. Seus *feedbacks* foram cuidadosos, mesmo em cenários de baixo desempenho dos alunos. Conclui-se que a utilização da IA em pesquisas educacionais pode prever problemas em sala de aula e que o uso generativo da IA pode ajudar a superar barreiras entre a cultura científica e os docentes.

Palavras-chave: Inteligência Artificial, atenção, educação, ensino.

Abstract

This study presents a generative Artificial Intelligence (AI) named Samantha, developed to investigate the relationship between attention and learning. The research focuses on the predictive capability of attention in educational conflicts and classroom performance. A psychometric application called iGnosi was created, classifying attention into four categories: Focused, Alert, Divided, and Alternating. Psychometric data were collected from 144 undergraduate students. For Samantha's development, the base model GPT-3.5 turbo 125 was used, trained with a dataset containing 577 entries for three roles: *System*, *User*, and *Assistant*. The training involved 307,266 tokens over 3 epochs, resulting in a loss of 0.0318. In initial tests, Samantha demonstrated the ability to interpret and guide researchers and educators based on the results, proving to be inspiring and motivating. Her feedback was careful, even in low-performance scenarios of the students. It is concluded that the use of AI in educational research can predict classroom problems and that the generative use of AI can help bridge the gap between scientific culture and educators.



Keywords: Artificial Intelligence, attention, education, teaching.

Introdução

Este trabalho é fruto de uma pesquisa em andamento, onde é investigada a relação da atenção com o aprendizado. O estudo se desmembrou para o desenvolvimento de uma inteligência artificial (IA) chamada Samantha, cujo objetivo é auxiliar na pesquisa com orientações, *insights* e de forma preditiva. Seu método de trabalho atual depende de um ecossistema que será melhor detalhado mais adiante.

As motivações do estudo passaram pela constatação dos desafios educacionais que o Brasil vem enfrentando. Começando pelo resultado do país no Programa Internacional de Avaliação de Estudantes (PISA), do ano de 2018. Nesse ano em particular, o Brasil figurou em 54º lugar (Brasil, 2020). Há críticas a este modo de avaliação padronizada e universalizada. Uma das principais, é sua forma comparativa e competitiva, que pouco considera as diferenças culturais e os referenciais históricos dos povos envolvidos (D'Ambrósio, 2005). Todavia, as evidências das dificuldades educacionais não param por aí.

Em 1984, foi detectado que em um intervalo de 46 anos, os índices do coeficiente de inteligência (QI) da humanidade aumentaram em média 14 pontos. Apontando assim, uma tendência à performance de uma geração ser melhor que a anterior (Flynn, 1984). Para o autor do estudo, James R. Flynn (1987), o QI não deve ser visto como o índice real de inteligência, mas sim como a capacidade de resolução de problemas abstratos. Porém, a tendência se reverteu a partir do início do século XXI e os índices de QI começaram a cair, especialmente em países com fácil acesso a tecnologias. A cultura de telas e dispositivos eletrônicos teria levado as gerações mais novas a uma mudança de hábitos, afastando-as do pensamento formal indo em direção ao concreto (Flynn; Shayer, 2018).

Fatores sociais e emocionais podem impactar o desempenho escolar durante o processo de aprendizagem. No entanto, em processos avaliativos, como o PISA, as habilidades cognitivas, compreendidas como memória, raciocínio, resolução de problemas e atenção, apresentaram grande impacto na performance (Sasaki *et al.*, 2018). Sobre a atenção, ainda há de se destacar que seu papel funciona como um preditor de problemas de aprendizado, dificuldades escolares e violação de regras (Marturano; Carla; Elias, 2016). Por este motivo, apesar da tecnologia em desenvolvimento, o projeto foi desenhado em direção ao entendimento do papel da atenção no aprendizado.

As pesquisas na área de educação também passam por desafios análogos à área. O principal é o custo do material psicométrico fidedigno e padronizado. Esses testes costumam ser desenvolvidos por empresas estrangeiras, o que encarece sua adaptação, adequação e ficam menos acessíveis. Somado a isto, existe a barreira técnica que impede a compreensão dos dados por todos os atores envolvidos no processo de ensino e aprendizado. Isto se deve à cultura científica, calcada na construção de uma sociedade baseada em seus saberes, com seus métodos, linguagens e processos (Lordêlo; Porto, 2012). E para superar esta barreira, foi proposta uma ferramenta psicométrica que fizesse interface a uma IA por meio de um *Large Language Model* (LLM).

A aplicação multiplataforma foi nomeada iGnosiⁱ e a IA que se comunicaria via LLM, de Samantha. A Samantha possui o propósito de facilitar a comunicação e o feedback entre os diversos atores envolvidos no processo de pesquisa em ensino e no ensino. Os resultados e análises produzidos a partir desta solução dependem do produto da integração entre as bibliotecas, servidores e modelos envolvidos no ecossistema criado. Sendo a atenção a métrica preditora de problemas de aprendizado e escolares, e alvo da IA Samantha.

A atenção como preditora e as classificações adotadas

A atenção é normalmente definida como um constructo complexo que interage entre si. Ela permite que os indivíduos filtrem e selecionem as informações mais interessantes para si (Shayer *et al.*, 2015). Essa habilidade cognitiva é associada a importantes preditores de problemas educacionais. Além dos problemas apresentados na introdução deste trabalho, quedas atencionais podem revelar casos de Transtorno do Déficit de Atenção e Hiperatividade (TDAH) (Moura; Silva, 2019). Observar o cenário das habilidades atencionais dos discentes pode ajudar o docente a prevenir conflitos escolares, ou determinar o papel do método pedagógico no ensino.

A atenção é enviesada, e aspectos da experiência do aluno na sala de aula podem mudar como ela age. Se a vivência do discente é positiva, seu sistema límbico o vai recompensar, priorizando situações similares (Anderson, 2016). Da mesma forma, se a experiência em sala de aula for desprazerosa, seu sistema límbico vai modular a atenção para trabalhar com medo preditivo (Sharpe; Killcross, 2015). Entendendo os aspectos preditores e moduladores da

atenção, ela foi selecionada como habilidade cognitiva de referência para o desenvolvimento de todo o sistema.

Para fins de padronização, foi utilizado neste projeto as classificações mais comuns em testes psicométricos: Atenção Concentrada (CON), Alerta ou Vigilância (ALE), Atenção Dividida (ADI) e Atenção Alternada (ALT). A padronização adotada é crítica para que a IA saiba como interpretar e tratar os resultados consultados.

Outra padronização comum utilizada, foram os grupos qualitativos. Como os dados são obtidos por meio de psicometria, a pontuação precisou ser tratada em grupos que representam a posição esperada para o grupo do aluno. Embora o escore Z tenha sido o parâmetro de tratamento dos dados, o produto foi convertido para uma escala onde a média absoluta é sempre 100. Esta é uma prática comum em diversos testes psicométricos, como a escala Wechsler. Veja o Quadro 1:

Quadro 1: Classificação qualitativa

Pontuação	Classificação
Abaixo de 70	Muito Baixo
De 70 a 79	Baixo
De 80 a 89	Médio Baixo
De 90 a 109	Médio
De 110 a 119	Médio Alto
De 120 a 129	Alto
130 ou mais	Superior

Fonte: Dados da pesquisa

Detalhes sobre a coleta, relevância estatística e métodos estatísticos de conversão, serão mais bem explicados na próxima sessão.

Coleta dos dados psicométricos


Foi utilizada amostra aleatória de voluntários da população universitária dos cursos de graduação da Universidade Estadual do Norte Fluminense (UENF), em Campos dos Goytacazes, interior do estado do Rio de Janeiro. Foram 144 indivíduos, de uma população de 2163 discentes. O grau de confiança atual é de 95% com margem de erro em 7,9%. A fórmula estatística para cálculo do tamanho é representada da seguinte forma (Barbetta, 2012):

$$Tamanho\ da\ amostra = \frac{\frac{z^2 \cdot p(1-p)}{e^2}}{1 + \left(\frac{z^2 \cdot p(1-p)}{e^2 N}\right)}$$

Onde N é o tamanho da população, e é a margem de erro, p a variabilidade (0.5) e z representa o escore Z .

Dos alunos participantes, 37 declararam ser do sexo masculino, 103 informaram serem do sexo feminino e 2 indivíduos foram registrados como não especificado e não binário.

Figura 1 - Distribuição da amostra



Fonte: Dados da pesquisa

Esses alunos foram submetidos a atividades atencionais do app iGnosi (figura 2). Essas atividades se propuseram a testar a atenção com quatro classificações: Concentrada, Alerta ou Vigilância, Dividida e Alternada. A aplicação foi construída utilizando código C#, XAM e JSON. Para proteger a privacidade dos envolvidos, o app gerou códigos alfanuméricos de 6 dígitos para cada indivíduo. A criptografia utilizou combinação de BCrypt com Saltⁱⁱ.

As notas dos testes foram convertidas em um escore Z , assim toda média absoluta retorna zero. Na sequência, o escore Z é multiplicado por 15 e somado a 100. Este cálculo é necessário para a padronização dentro das práticas mais comuns em testes psicológicos. Sendo assim, a nota, ou quantidade de acertos não é tão relevante. A relevância é o quanto é esperado

que o indivíduo pontue em relação ao grupo que está inserido. Por fim, o algoritmo passa a ser capaz de agrupar as notas qualitativamente, conforme Quadro 1.

O escore Z foi obtido pela seguinte fórmula: $Z = \frac{x - \text{média}}{\sigma}$. Sendo x a nota do indivíduo no teste atencional específico (CON, ALE, ADI ou ALT), e σ o desvio padrão. Todos os dados são obtidos pelo algoritmo durante a fase de padronização do escore. Com todas as métricas padronizadas, os dados estão prontos para serem interpretados pela IA via contexto.

Figura 2: Capturas de telas com cadastros e instruções de atividades atencionais da aplicação iGnosi



Fonte: Dados da pesquisa

A partir deste ponto, foi proposta uma solução em inteligência artificial. Se considerou importante que os dados pudessem ser interpretados por níveis diferentes de indivíduos envolvidos no processo de ensino.

Ensinando uma Inteligência Artificial a entender a relação entre educação e atenção


A ciência já incorporou as IAs em seu método em diversos campos de conhecimento. Na medicina, já se encontram iniciativas preditivas. Um dos usos, por exemplo, envolve a combinação de *machine learning* (ML), *deep learning* (DP) e processamento de linguagem natural (PNL) na detecção de deficiências neuro cognitivas (Graham *et al.*, 2020). Enquanto no ML o algoritmo reconhece padrões tentando prever resultados futuros, no DL trabalha com várias camadas de dados complexos e não estruturados. É importante destacar que o DL é um subconjunto do ML.

O formato atual dos dados já permite o tratamento por *machine learning*. Todavia, sua aplicação no campo da educação depende da qualidade da interpretação dos dados. Foi optado por focar os esforços da IA no treinamento de um modelo *Large Language Model* (LLM). Esse

modelo será parte crucial da Samantha, nome dado à IA deste trabalho. LLM, ou modelos de linguagem de grande escala, são sistemas de *Deep Learning* preparados para processar imensas coleções de textos. Seu objetivo primário é prever a próxima palavra em uma frase ou parágrafo (Blank, 2023). Em sequência, são criados objetivos secundários. A IA passa a se chamar “modelo de linguagem”. No modelo de linguagem, a IA pode passar por um novo treinamento para um objetivo específico. Isso requer um grande domínio distribucional das palavras e estruturas sintáticas.

Para que a Samantha ficasse funcional, seria necessário que ela caminhasse por uma estrutura específica (figura 3). No fluxo criado, o iGnosi recebe informações do banco de dados, processa as informações, o modelo de linguagem interpreta e interage com o usuário.

Figura 3 - Fluxo de trabalho para a IA

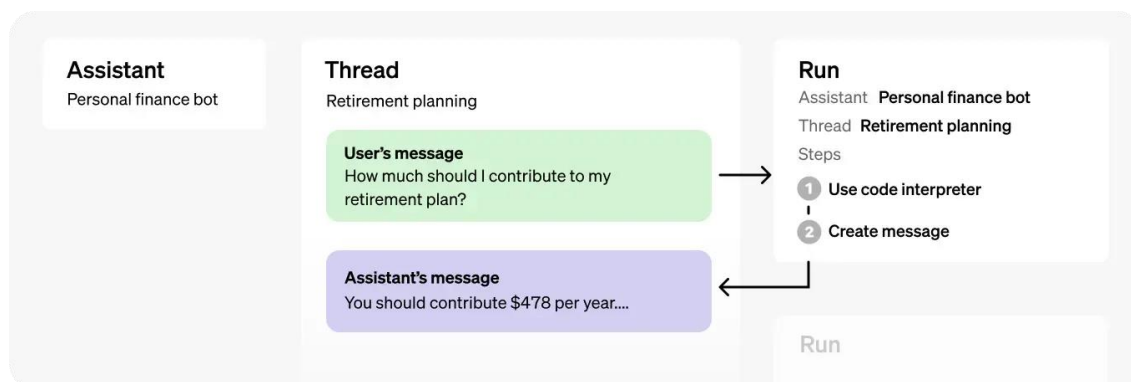


Fonte: Dados da pesquisa

Durante a etapa de treinamento do modelo de linguagem, foram considerados os seguintes modelos: LLMA, Gemini, GPT 4 e GPT 3.5 turbo 125. O modelo GPT 3.5 turbo 125 foi selecionado por apresentar melhor integração com o iGnosi. Outro motivo para a seleção do modelo, é o baixo custo para ter o processamento de LLM em nuvem. Os modelos GPTs são os mesmos utilizados como base para o popular chat GPT.

Por padrão, os assistentes criados utilizando os modelos GPT da OpenAI permitem acessar ferramentas externas em paralelo. Além disso, é possível criar tópicos persistentes para que as chamadas mantenham a coerência (OpenAI, 2024a). Sendo assim, quando o usuário envia uma mensagem, um tópico é aberto. O assistente é invocado no tópico e interpreta a mensagem. Em seguida ela é reenviada para o usuário. Veja o esquema na figura 4:

Figura 4 - Esquema de funcionamento de uma IA generativa



Fonte: disponível em platform.openai.com/docs/assistants/overview Acesso em: 17 Jul de 2024.


Essas características se mostraram desejáveis por permitirem a interação com todo o sistema deste trabalho. Além disso, este modelo possui plataforma própria para treinamento. Esta facilidade foi utilizada para compor todo o conhecimento da IA Samantha. Para o treinamento da Samantha, foi criado um *dataset*ⁱⁱⁱ contendo conhecimentos sobre neurociências, atenção, classificações de atenção, psicométrica, funcionamento da aplicação iGnosi e instruções de boas práticas em seus *feedbacks*. Era importante que a Samantha fosse inspiradora e motivadora em suas respostas. Mesmo em um cenário de resultados abaixo do esperado, ela deve orientar sem alarmar. Também foi incluída instruções explicando que fatores externos podem influenciar o resultado. Além de orientações para busca de profissionais adequados para investigar qualquer alteração no resultado.

Para os ajustes, as IAs deste modelo, esperam exemplos de diálogos com três papéis (ou *roles*). São eles: *System*, *User*, *Assistant*. *System* são as instruções sobre o conhecimento e comportamento da IA. É por este papel que informamos os dados críticos para seu funcionamento. O app iGnosi tira proveito desta característica e envia alguns dados previamente processados através de *System*. Já *User*, no treinamento representa um exemplo de questionamento do usuário. Este papel permite montar um cenário específico para o funcionamento da IA. E por fim o *Assistant*, que é resposta esperada da inteligência artificial (OpenAI, 2024b).

O primeiro *dataset* da Samantha foi produzido com 140 linhas. Nele incluíam instruções básicas sobre como interpretar resultados psicométricos de atenção. Além da identidade e comportamento esperado da IA. O teste consumiu 50.122 tokens e levou 3 epochs^{iv}. Porém suas

perdas de treinamento (training loss) ficaram em 1.4828 (figura 5). Quanto mais próximo de zero, melhor é o resultado. Neste caso, o resultado foi insatisfatório.

Figura 5 - Primeiro treino da Samantha




Fonte: Dados da pesquisa

Com os primeiros resultados inconsistentes, um novo *dataset* foi produzido. Desta vez foi produzido um *dataset* com 577 linhas (figura 7). Em todas as entradas o papel *System* informou que “Samantha é uma assistente gentil, motivadora e inspiradora.”. Foi realizado desta forma para ajustar o comportamento da Samantha. Este papel será novamente ajustado pelo algoritmo do iGnosi no estágio de integração do sistema. Além das informações anteriores, foram acrescentados gatilhos. Esses gatilhos são palavras chaves específicas para a IA retornar análises completas. Neste segundo treinamento, o resultado foi positivo. O modelo teve uma perda de treino de 0.0318. O custo de *tokens* foi de 307266, com o treino realizado em 3 *epochs*

(figura 6). A Samantha passou a retornar dados mais consistentes e seus erros foram minimizados. Sendo o passo seguinte a integração do modelo de linguagem com a aplicação iGnosi.

Figura 6 - Segundo treino da Samantha



Fonte: Dados da pesquisa

Figura 7 - Três entradas do dataset

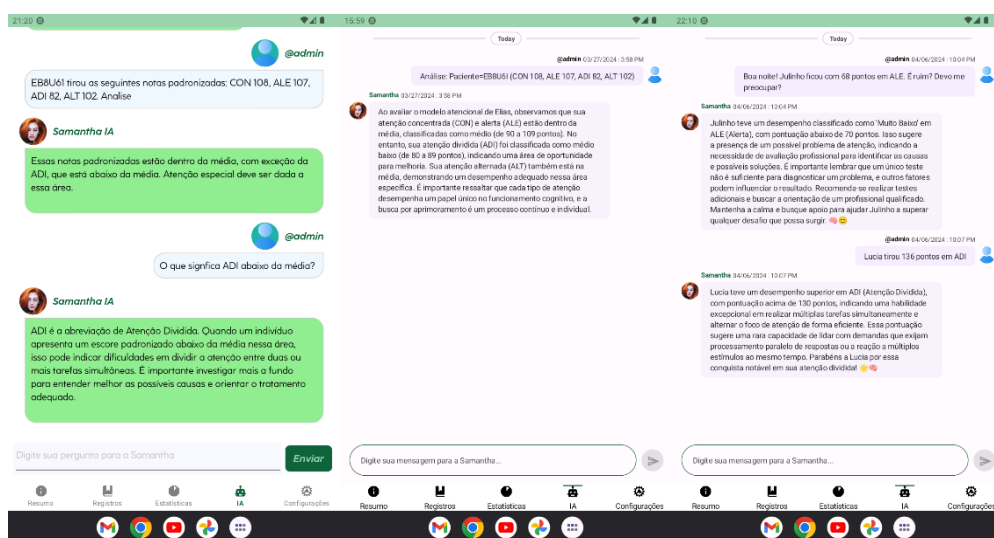
```
[{"messages": [{"role": "system", "content": "Samantha \u00e9 uma assistente gentil, motivadora e inspiradora."}, {"role": "user", "content": "Jo\u00e3o realizou o teste de Aten\u00e7\u00e3o Alternada (ALT) e obteve 94 pontos. O que isso revela sobre sua capacidade de alternar o foco atencional?"}, {"role": "assistant", "content": "Jo\u00e3o teve um desempenho m\u00e9dio em Aten\u00e7\u00e3o Alternada (ALT), com pontua\u00e7\u00e3o entre 90 e 109 pontos. Isso indica que ele est\u00e1 dentro da normalidade em alternar entre duas ou mais atividades sem perder o foco. Notas nessa faixa s\u00e3o classificadas como m\u00e9dio, sugerindo normalidade em processar resposta ou a reagir a duas ou mais demandas ao mesmo tempo. \u00c9 recomend\u00e1vel continuar praticando para fortalecer essas habilidades cognitivas."}], [{"role": "system", "content": "Samantha \u00e9 uma assistente gentil, motivadora e inspiradora."}, {"role": "user", "content": "Maria fez o teste de Aten\u00e7\u00e3o Alternada (ALT) e obteve 103 pontos. O que isso revela sobre sua capacidade de alternar o foco atencional?"}, {"role": "assistant", "content": "Maria teve um desempenho m\u00e9dio em Aten\u00e7\u00e3o Alternada (ALT), com pontua\u00e7\u00e3o entre 90 e 109 pontos. Isso indica que ela est\u00e1 dentro da normalidade em alternar entre duas ou mais atividades sem perder o foco. Notas nessa faixa s\u00e3o classificadas como m\u00e9dio, sugerindo normalidade em processar resposta ou a reagir a duas ou mais demandas ao mesmo tempo. Parab\u00e9ns pelo desempenho e continue se esfor\u00e7ando para manter suas habilidades \u00e1geis!"}], [{"role": "system", "content": "Samantha \u00e9 uma assistente gentil, motivadora e inspiradora."}, {"role": "user", "content": "Pedro obteve uma pontua\u00e7\u00e3o de 96 pontos no teste de Aten\u00e7\u00e3o Alternada (ALT). O que isso revela sobre sua capacidade de alternar o foco atencional?"}, {"role": "assistant", "content": "Pedro teve um desempenho m\u00e9dio em Aten\u00e7\u00e3o Alternada (ALT), com pontua\u00e7\u00e3o entre 90 e 109 pontos. Isso indica que ele est\u00e1 dentro da normalidade em alternar entre duas ou mais atividades sem perder o foco. Notas nessa faixa s\u00e3o classificadas como m\u00e9dio, sugerindo normalidade em processar resposta ou a reagir a duas ou mais demandas ao mesmo tempo. Continue praticando para fortalecer suas habilidades cognitivas."}]
```

Fonte: Dados da pesquisa

Com a etapa de LLM pronta, todo o ecossistema que compõe a Samantha foi integrado. Houve uma evolução técnica entre os protótipos, que poderá ser observado na figura 8. A Samantha passou a ser acionada por uma janela de chat na área logada da aplicação iGnosi. Os tópicos com a conversa e contexto são gerenciados pela aplicação (figura 9). O papel do servidor da OpenAI ficou limitada a processar o contexto em forma de linguagem natural. Enquanto o armazenamento dos dados ficou a cargo do *Google Firebase*.

Para evitar falhas e mitigar qualquer desinformação acidental, foram tomadas medidas pelo algoritmo do iGnosi. A criatividade da Samantha foi limitada por uma propriedade chamada *temperature*. Esse parâmetro define o quão criativa uma IA pode ser. Se ela for muito criativa, as respostas podem se distanciar da realidade. Portanto, a criatividade da Samantha foi restringida. Outra medida, foi o balanceamento do contexto. O tópico da conversa cresce a cada mensagem enviada. Isso aumenta o processamento e os custos. A aplicação gerencia o tamanho do tópico e através de *System* ele resume o contexto da conversa, antes de se processar a solicitação atual do usuário.

Figura 8 - Evolução da interface da Samantha




Fonte: Dados da pesquisa

Nos últimos testes, a Samantha foi capaz de produzir *feedbacks* claros sobre os alunos da UENF. A IA se preocupou em inspirar e motivar o usuário. Também foi capaz de esclarecer resultados negativos sem alarmar o interlocutor. Além disso, ela explica que um único teste não é suficiente para avaliar um indivíduo e que um especialista deve ser consultado.

As vantagens observadas ao utilizar uma IA em uma aplicação para pesquisa em educação foram, mas não se limitam:

- Alta adaptabilidade ao discurso do usuário;
- Funcionou como uma facilitadora da compreensão dos dados coletados;
- Excelente compreensão a diversos usos de linguagem. A IA se mostrou flexível quanto a gírias, jargões e coloquialismo;
- Capaz de gerar múltiplos exemplos, para públicos diferentes;
- Configurável para trabalhar com níveis de formações diferentes;
- Capaz de auxiliar professores, alunos, pais e pesquisadores.

Figura 9 - Ciclo de funcionamento da Samantha no iGnosi



Fonte: Dados da pesquisa

Implementações de inclusão

Em seu projeto original, o app iGnosi previu o seu uso inclusivo e acessível. Um módulo de voz natural já se encontra ativo na aplicação. Originalmente, este módulo servia de auxiliar

para ler as telas das atividades de atenção. A Samantha já é capaz de falar por ele. Sendo assim, auxiliando aqueles que tiverem problemas para ler os dados em forma de texto.

Infelizmente esta comunicação ainda é realizada por uma única via. Não é possível no momento que o usuário se comunique por áudio com o app. Ainda assim, pela natureza da IA é possível que ela interprete mensagens de áudio enviadas por humanos. Com adaptações e investimentos, o app poderá ser utilizado até por aqueles que possuam limitações visuais.

Conclusões e expectativas futuras

A Samantha demonstrou-se didática e promissora em suas respostas geradas. No presente momento, ela consegue discutir os escores e classificações da aplicação iGnosi. Também domina com certa segurança conhecimentos de neurociências, psicologia e educação. Seu discurso é desenhado para não substituir um psicólogo ou pedagogo, mas sugerir a procura do profissional. Com acesso aos escores de atenção, ela pode prever problemas em sala de aula e possíveis conflitos educacionais. Apesar do empirismo envolvido, o objetivo final é demonstrar o impacto qualitativo das alterações na atenção em sala de aula. Ela se demonstra capaz de orientar pesquisadores e docentes em intervenções pontuais.

É possível observar, através do senso comum, as preocupações dos impactos das IAs, especialmente na educação. A facilidade para se gerar textos não autorais e, principalmente, com informações inverídicas são questões preocupantes. Essas questões devem ser amplamente debatidas por envolverem a maneira como enfrentaremos os aspectos negativos de uma tecnologia tão poderosa. Todavia, este não é o todo das Inteligências Artificiais, muito menos seu propósito original. Elas possuem recursos que podem derrubar entraves antigos no campo da educação. Em especial, a comunicação entre todos os agentes envolvidos no sistema educacional.

A formação de professores e de pesquisadores do campo da educação encontra barreiras fundamentais. Com formações caminhando em direções diferentes, a interdisciplinaridade acaba por ser prejudicada. Embora muitos cursos de formação de docentes e pesquisadores se proponham a serem interdisciplinares, eles possuem cultura própria. Conhecimentos como pedagogia, psicologia, docência, metodologia científica, entre outros, carregam seu próprio conjunto de saberes, jargões e entendimento de como uma sociedade é construída. Porém, a

natureza não é cartesiana, muito menos o processo de ensino e aprendizagem. Cada discente tem suas necessidades sociais, psicológicas, didáticas e culturais. Ainda não há como garantir que todos os atores do processo de ensino estejam alinhados em seus entendimentos. Alguns dizem milhas, outros dizem quilômetros, mas todos estão falando da mesma coisa. Uma IA que usa LLM não tem problemas em ajustar seu discurso, sem perder o significante, independente do significado.

Professores, pedagogos e pesquisadores poderão futuramente utilizar a ferramenta para entender problemas de aprendizado em sala de aula. Graças à tecnologia LLM, Samantha poderá ajustar seu discurso para trabalhar em funções diferentes. Detalhes psicométricos deverão ficar restritos a psicólogos treinados, como é demandado pelo Conselho Federal de Psicologia (CFP). Para professores e pedagogos, os detalhes focarão nos impactos na sala de aula.

Os próximos passos envolvem explorar maiores integrações da Samantha com ferramentas externas. Também se planeja explorar LLMs abertos para funcionarem em um servidor aberto na Universidade. Após o estágio atual da pesquisa, é pretendido disponibilizar a aplicação para uso em outras universidades. É esperado que, com o uso integrado de IAs pesquisas possam ter seus processos acelerados. Outra vantagem é o barateamento dos custos para os pesquisadores. Esta vantagem ajuda a enfrentar a carência de recursos que as universidades vêm sofrendo, em especial nas áreas de educação.

As aplicações da tecnologia de inteligência artificial são amplas. A área de ensino e pesquisas em educação podem tirar proveito de sua versatilidade. No campo da pesquisa em educação, é promissora devido ao seu baixo custo e adaptação a diversas demandas. As IAs não são um fenômeno iminente. Elas já são a realidade do dia a dia. Cabe a nós descobrirmos como utilizá-las a nosso favor, para que elas sejam ferramentas e não o problema.

Referências

ANDERSON, Brian A. *The attention habit: how reward learning shapes attentional selection*. *Annals of the New York Academy of Sciences*, [s. l.], v. 1369, n. 1, p. 24–39, 2016. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1111/nyas.12957>. Acesso em: 14 jun. 2023.

BARBETTA, Pedro Alberto. *Estatística aplicada às Ciências Sociais*. 8. ed. Florianópolis: Editora UFSC, 2012.

BLANK, Idan A. *What are large language models supposed to model?*. *Trends in Cognitive Sciences*, [s. l.], v. 27, n. 11, p. 987–989, 2023. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S1364661323002024>. Acesso em: 16 jul. 2024.

BRASIL. *Brasil no Pisa 2018*. INEP/MEC, [s. l.], 2020. Disponível em: <https://www.gov.br/inep/pt-br/areas-de-atuacao/avaliacao-e-exames-educacionais/pisa/resultados>. Acesso em: 11 maio 2023.

D'AMBRÓSIO, Ubiratan. *Sociedade, cultura, matemática e seu ensino*. *Educação e Pesquisa*, [s. l.], v. 31, n. 1, p. 99–120, 2005. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1517-97022005000100008&lng=pt&tlng=pt. Acesso em: 19 jun. 2024.

FLYNN, James R. *Massive IQ gains in 14 nations: What IQ tests really measure*. *Psychological Bulletin*, [s. l.], v. 101, n. 2, p. 171–191, 1987. Disponível em: <http://doi.apa.org/getdoi.cfm?doi=10.1037/0033-2909.101.2.171>.

FLYNN, James R. *The mean IQ of Americans: Massive gains 1932 to 1978*. *Psychological Bulletin*, [s. l.], v. 95, n. 1, p. 29–51, 1984. Disponível em: <http://doi.apa.org/getdoi.cfm?doi=10.1037/0033-2909.95.1.29>.

FLYNN, James R.; SHAYER, Michael. *IQ decline and Piaget: Does the rot start at the top?*. *Intelligence*, [s. l.], v. 66, p. 112–121, 2018.

GRAHAM, Sarah A. et al. *Artificial intelligence approaches to predicting and detecting cognitive decline in older adults: A conceptual review*. *Psychiatry Research*, [s. l.], v. 284, p. 112732, 2020. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0165178119320839>. Acesso em: 18 maio 2023.

LORDÊLO, Fernanda Silva; PORTO, Cristiane de Magalhães. *Divulgação científica e cultura científica: Conceito e aplicabilidade*. *Revista Ciência em Extensão*, [s. l.], v. 8, n. 1, p. 18–34, 2012. Disponível em: https://ojs.unesp.br/index.php/revista_proex/article/view/515. Acesso em: 18 jun. 2024.

MARTURANO, Edna Maria; CARLA, Luciana; ELIAS, Santos. *Família, dificuldades no aprendizado e problemas de comportamento em escolares*. *Educar em Revista*, [s. l.], n. 59, p. 123–139, 2016. Disponível em: <http://www.scielo.br/j/er/a/hZc8jnYNJDsW9tFMP3tbBjd/?lang=pt>. Acesso em: 23 abr. 2023.

MOURA, Luciana Teles; SILVA, Katiane Pedrosa Mirandola. *O Transtorno de Déficit de Atenção e Hiperatividade (TDAH) e as práticas pedagógicas em sala de aula*. *Revista Eletrônica Acervo Saúde*, [s. l.], n. 22, p. e216–e216, 2019. Disponível em: <https://acervomais.com.br/index.php/saude/article/view/216>. Acesso em: 14 maio 2023.

OPENAI. *Assistants overview - OpenAI API*. [S. l.], 2024a. Disponível em: <https://platform.openai.com/docs/assistants/overview>. Acesso em: 16 jul. 2024.

OPENAI. *Fine-tuning - OpenAI API*. [S. l.], 2024b. Disponível em: <https://platform.openai.com/docs/guides/fine-tuning>. Acesso em: 16 jul. 2024.

SASSAKI, Alex Hayato et al. *Por que o Brasil vai Mal no PISA? Uma Análise dos Determinantes do Desempenho no Exame*. INSPER, [s. l.], 2018. Disponível em: <https://www.researchgate.net/publication/326718184>. Acesso em: 12 maio 2023.

SHARPE, Melissa J.; KILLCROSS, Simon. *The prelimbic cortex directs attention toward predictive cues during fear learning*. *Learning & Memory*, [s. l.], v. 22, n. 6, p. 289–293, 2015. Disponível em: <http://learnmem.cshlp.org/lookup/doi/10.1101/lm.038273.115>. Acesso em: 14 jun. 2023.

SHAYER, Beatriz et al. *Desempenho de escolares em atenção e funções executivas no Nepsy e inteligência*. *Revista Psicologia: Teoria e Prática*, [s. l.], v. 17, n. 1, p. 120–135, 2015. Disponível em: <http://editorarevistas.mackenzie.br/index.php/ptp/article/view/6980>. Acesso em: 20 mar. 2023.

ⁱ Programa de computador registrado no Instituto Nacional da Propriedade Industrial (INPI) no processo número BR512024001850-6.

ⁱⁱ Bcrypt é uma função de hashing adaptativa utilizada para proteger senhas armazenadas. Ele incorpora um Salt, um valor aleatório adicionado à senha antes do hashing, para garantir que senhas iguais resultem em hashes diferentes. Isso aumenta a segurança, tornando ataques de dicionário e ataques de força bruta menos eficazes. A natureza adaptativa do Bcrypt também permite que ele se torne mais lento ao longo do tempo, o que aumenta a dificuldade de ataques conforme o poder computacional aumenta.

ⁱⁱⁱ São bases de dados que servem de amostras para treinamento de algoritmo de inteligência artificial.

^{iv} Se refere a um ciclo completo de treinamento.