

Do Rastreamento à Evolução Clínica: Um Sistema de Prontuário Inteligente para TEA Baseado em Agentes de IA e Análise Semântica



Vagner Alves Ferreira da Silva

vafs@discente.ifpe.edu.br

Hélio Fernando Bentzen Pessoa Filho

Helio.filho@palmares.ifpe.edu.br

RESUMO

O diagnóstico precoce do Transtorno do Espectro Autista (TEA) é determinante para o prognóstico clínico, dependendo frequentemente da análise ágil de instrumentos de triagem e dados sociodemográficos. Este trabalho apresenta o desenvolvimento de um sistema de análise de dados assistido por Inteligência Artificial (IA), projetado para otimizar a interpretação de datasets de rastreamento de autismo. O método adotado utilizou a linguagem Python e o framework Streamlit para criar uma aplicação web que integra Agentes de IA baseados em Grandes Modelos de Linguagem (LLMs) via LangChain. Diferente de chatbots convencionais, o sistema implementa uma arquitetura "Human-in-the-Loop", permitindo que o profissional de saúde audite o código de análise gerado em tempo real. A validação foi realizada utilizando o dataset Autism Screening for Toddlers, processando pontuações do questionário Q-CHAT-10 para identificar correlações e prevalência de traços. Os resultados demonstram uma plataforma funcional capaz de realizar análises exploratórias complexas, gerar visualizações de distribuição de risco e fornecer insights explicáveis, apoiando a tomada de decisão na triagem clínica.

Palavras-chave: Inteligência Artificial. Triagem de Autismo. Q-CHAT-10. Agentes Inteligentes. Suporte à Decisão.

ABSTRACT

Early diagnosis of Autism Spectrum Disorder (ASD) is crucial for clinical prognosis, often relying on the agile analysis of screening instruments and sociodemographic data. This work presents the development of an Artificial Intelligence (AI) assisted data analysis system designed to optimize the interpretation of autism screening

datasets. The methodology employed Python and the Streamlit framework to create a web application integrating AI Agents based on Large Language Models (LLMs) via LangChain. Unlike conventional chatbots, the system implements a "Human-in-the-Loop" architecture, allowing health professionals to audit the analysis code generated in real-time. Validation was performed using the Autism Screening for Toddlers dataset, processing Q-CHAT-10 scores to identify correlations and trait prevalence. The results demonstrate a functional platform capable of performing complex exploratory analyses, generating risk distribution visualizations, and providing explainable insights, thereby supporting decision-making in clinical screening.

Keywords: Artificial Intelligence. Applied Behavior Analysis. Intelligent Agents. Python. Digital Health.

1 INTRODUÇÃO

O Transtorno do Espectro Autista (TEA) é uma condição neurobiológica complexa que impacta o desenvolvimento social, emocional e econômico, sendo o diagnóstico precoce um fator determinante para a eficácia das intervenções terapêuticas e para a promoção da inclusão social e autonomia da criança (MOREIRA; LIMA; HOUNSELL, 2025). No entanto, a prática clínica enfrenta obstáculos substanciais, uma vez que o diagnóstico é predominantemente observacional e dependente da expertise profissional para interpretar a variabilidade de sintomas, o que frequentemente resulta em avaliações tardias e subjetivas (JENDREIECK, 2014).

Diante desse cenário, a tecnologia oferece novos paradigmas para a saúde mental. A aplicação de Inteligência Artificial (IA) e aprendizado de máquina (*machine learning*) tem demonstrado potencial para processar dados clínicos massivos, permitindo a construção de modelos que aumentam a automação e a eficiência da triagem e do diagnóstico precoce do autismo (ZHANG, 2025). O desenvolvimento de agentes inteligentes capazes de analisar tais dados visa, portanto, superar as barreiras de tempo e recursos humanos, oferecendo suporte à decisão clínica com maior precisão e rapidez.

Entretanto, a adoção de modelos de 'caixa-preta' na saúde enfrenta desafios críticos relacionados à interpretabilidade e confiança. Profissionais clínicos necessitam não apenas de previsões probabilísticas, mas de ferramentas que

permitam a exploração dinâmica dos dados e forneçam justificativas claras para suas análises. É neste nicho que os Grandes Modelos de Linguagem (LLMs), integrados a agentes de software, se tornam uma alternativa robusta, devido à sua capacidade de interpretar comandos em linguagem natural e executar tarefas complexas de análise de dados de forma transparente.

Neste contexto, este trabalho apresenta o desenvolvimento de um sistema de análise clínica assistido por agentes inteligentes, utilizando a abordagem *Human-in-the-Loop*. Diferente de modelos puramente preditivos, a solução proposta utiliza a biblioteca LangChain para orquestrar agentes capazes de manipular *dataframes* via Pandas, gerando e executando código em tempo real. O objetivo é fornecer aos terapeutas uma ferramenta que automatiza a extração de *insights* a partir de instrumentos de triagem e dados sociodemográficos, mantendo a explicabilidade do processo e a validação humana como pilares centrais da decisão clínica.

2 Fundamentação teórica

A construção de ferramentas computacionais para o suporte ao diagnóstico e tratamento do Transtorno do Espectro Autista (TEA) exige a convergência de três pilares fundamentais: a complexidade clínica da análise comportamental (ABA), a necessidade de confiança em sistemas de Inteligência Artificial (IA Explicável) e a conformidade com a proteção de dados sensíveis (LGPD).

2.1 Fundamentos dos Agentes de Inteligência Artificial

A evolução da Inteligência Artificial permitiu o surgimento dos chamados “Agentes”. Diferentemente dos grandes modelos de linguagem (Large Language Models – LLMs) tradicionais, como *ChatGPT*, *Gemini* e *Deepseek*, que focam no processamento de texto, os agentes utilizam ferramentas externas para executar tarefas específicas. Eles têm a capacidade de resolver problemas complexos, como design de software, geração de código, automação de mídias sociais, assistência por voz ou texto e análise de dados, superando as limitações das LLMs convencionais.

No contexto deste trabalho, são utilizados agentes capazes de manipular e analisar dados clínicos, apresentando os resultados dessas análises em formato de texto e voz.

2.1.1 Agentes Inteligentes e Análise de Dados

Para a manipulação e análise de dados clínicos, foram utilizados agentes capazes de operar com a biblioteca *Python* Pandas. Conforme McKinney (2010), essa ferramenta foi desenvolvida para fornecer estruturas de dados flexíveis, projetadas especificamente para facilitar o trabalho com dados estruturados e séries temporais, constituindo um bloco fundamental para a computação estatística em *Python*.

Já para a orquestração dos modelos de linguagem e a integração com ferramentas externas, adotou-se o *framework* *LangChain*. Segundo Chase (2022), essa ferramenta viabiliza o desenvolvimento de aplicações em que o modelo de linguagem não se limita ao processamento de texto, mas também interage com outras fontes de dados e executa ações, sendo essencial para a construção de agentes autônomos.

2.1.2 Sistemas de Apoio à Decisão Clínica (CDSS) e Necessidade de Confiança

O software desenvolvido neste trabalho classifica-se como um Sistema de Apoio à Decisão Clínica (Clinical Decision Support System – CDSS). Diferente de sistemas puramente diagnósticos que visam substituir o médico, esses sistemas são projetados para ampliar a capacidade cognitiva do profissional, filtrando informações e sugerindo hipóteses baseadas em dados.

Um obstáculo central para a adoção de IA na saúde é o problema da “Caixa Preta”(Black Box), Conforme destacam Holzinger et al. (2019), na medicina, a opacidade dos algoritmos é uma barreira crítica. A transparência algorítmica não é apenas uma exigência técnica, mas ética, sendo necessário que os especialistas humanos compreendam a causalidade das decisões da IA para validá-las com segurança. Algoritmos complexos (como Redes Neurais Profundas) geram resultados sem explicar o raciocínio subjacente. Revisões sistemáticas recentes

(2004-2025) apontam que a confiabilidade (*trust*) e a transparência são os fatores determinantes para que profissionais de saúde aceitem utilizar uma IA.

Para mitigar esse risco, este trabalho adota o paradigma da IA Explicável (XAI-Explainable AI). Ao utilizar uma arquitetura baseada em agentes que geram e executam código (ex: Python/Pandas) para responder a perguntas clínicas, o sistema opera como uma “Caixa de Vidro”. O terapeuta não recebe apenas uma previsão probabilística opaca, mas pode auditar o processo lógico (o código gerado) e os dados brutos utilizados para chegar a conclusão, garantindo que a decisão final permaneça sob controle humano (*Human-in-the-Loop*).

2.2 Proteção de Dados e Ética (LGPD)

O tratamento de dados de saúde no Brasil é regido pela Lei Geral de Proteção de Dados (Lei nº 13.709/2018 – LGPD). O Artigo 5º classifica dados referentes à saúde como *dados pessoais sensíveis*, exigindo salvaguardas rigorosas. O artigo 11 veda o tratamento desses dados para fins discriminatórios e impõe que o uso para pesquisa ou desenvolvimento de software garanta a anonimidade ou o consentimento dos responsáveis legais.

Para o desenvolvimento e validação deste sistema no âmbito acadêmico, sem expor pacientes reais a riscos de privacidade, optou-se pela utilização do conjunto de dados *Toddler Autism Dataset*. Esses dados replicam as propriedades estatísticas de populações clínicas reais, sem violar a confidencialidade dos pacientes, permitindo o teste seguro de agentes de IA sobre esses dados.

2.3 Trabalhos Relacionados

A aplicação de Inteligência Artificial no suporte ao diagnóstico de TEA tem sido amplamente explorada na literatura recente. Wang et al. (2025) descrevem a emergência da "Agentic AI" na saúde, onde agentes autônomos planejam tarefas e acessam ferramentas externas, superando a limitação dos chatbots passivos. Estudos recentes do *Mila - Quebec AI Institute* (2025) demonstraram o uso de LLMs para decodificar padrões clínicos em textos médicos. No entanto, a maioria dessas abordagens opera como "Caixa Preta". A proposta deste trabalho se diferencia ao

implementar uma arquitetura *Glass Box*, onde o foco não é apenas a automação, mas a entrega do código de análise auditável ao profissional

3 METODOLOGIA

Este trabalho consiste no desenvolvimento de um artefato de software para auxílio à decisão clínica. O sistema foi implementado utilizando a linguagem de programação Python em sua versão 3.11, selecionada por sua predominância em ciência de dados e um vasto ecossistema de bibliotecas de inteligência artificial.

3.1 Arquitetura

A aplicação adota uma arquitetura monolítica modular, onde a interface de usuário, a lógica de negócio e o gerenciamento de dados residem na mesma instância de execução, facilitando a implantação em ambientes locais ou servidores privados.

A interface gráfica do software foi construída utilizando o framework *Streamlit*, que permite a renderização reativa de componentes web.

O sistema foi projetado para ser agnóstico em relação ao Modelo de Linguagem (LLM) utilizado. Durante o ciclo de desenvolvimento e validação, o software foi configurado e testado com dois provedores distintos de inferência: a API da OpenAI (utilizando o modelo GPT-4) e a plataforma NVIDIA NIM (utilizando o modelo *open-weights* Llama-3.3-Nemotron-Super-49B-v1.5). Essa abordagem híbrida permitiu avaliar a robustez do agente em dois cenários: nuvem (GPT-4) e local/privado (Llama-3 via NVIDIA NIM). Em um cenário de produção real, a utilização de modelos *open-weights* (como o Llama-3) rodando em infraestrutura local (*on-premise*) é a arquitetura recomendada para garantir a conformidade com a LGPD e normas de *compliance* hospitalar, assegurando que dados sensíveis de pacientes jamais trafeguem para servidores de terceiros ou sejam usados para treinamento de modelos públicos.

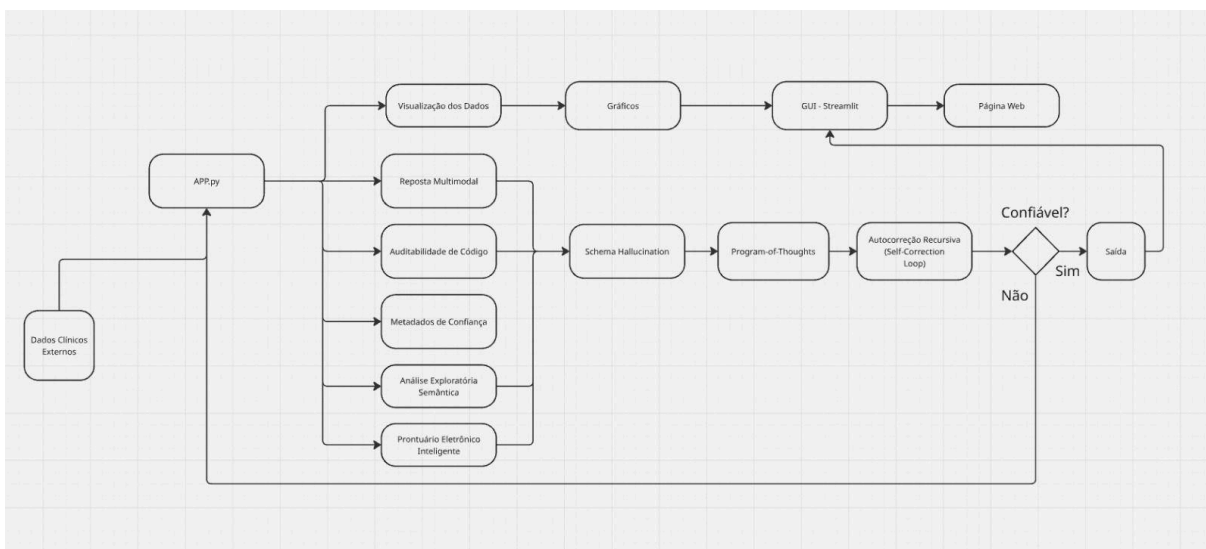
3.2 Implementação dos Agentes Inteligentes

O componente central do sistema é o "Analista de Inteligência Artificial", implementado no módulo `ai_analyst.py`. Diferente de sistemas convencionais baseados apenas em *prompts* de texto genéricos, este trabalho utilizou a biblioteca **LangChain** para instanciar agentes capazes de manipular dados estruturados de triagem. A arquitetura adota uma estratégia de "Agente Dual" para maximizar a precisão na detecção de padrões:

- **Agente de Análise de Triagem:** Utiliza a função `create_pandas_dataframe_agent` para raciocínio lógico e estatístico sobre o dataset Q-CHAT-10. Foi aplicada uma técnica de engenharia de *prompt* onde o sistema injeta, antes de cada consulta, um contexto rígido contendo o esquema dos dados (pontuações, variáveis demográficas) e diretrizes de atuação. O modelo é instruído a comportar-se como um "Especialista em Análise de Dados de Saúde", baseando suas inferências estritamente nas variáveis de risco presentes no dataset.
- **Agente de Visualização:** Para a geração de gráficos de distribuição e risco, o sistema utiliza uma função dedicada (`generate_visualization_code`) otimizada para a biblioteca **Plotly Express**. Esta segregação de responsabilidades evita que a lógica de visualização interfira na interpretação estatística dos dados de triagem.

O fluxo de processamento inicia-se quando o usuário insere uma pergunta em linguagem natural (ex: "*Qual a prevalência de risco em crianças com histórico familiar de TEA?*"). O agente interpreta a estrutura do *DataFrame*, escreve e executa um código Python temporário para realizar o cruzamento de dados exato e, por fim, o sistema retorna tanto a resposta textual (e auditiva) quanto o código gerado, garantindo a auditabilidade do processo, conforme detalhado no fluxo de arquitetura apresentado na figura abaixo.

Figura 1: Fluxograma da Arquitetura do Sistema.



Fonte: Próprio Autor.

3.3 Transparência Algorítmica (Abordagem *Glass Box*)

Para mitigar o problema da "Caixa Preta" em sistemas de apoio ao diagnóstico, a interface da aplicação (`app.py`) foi projetada para operar como uma "Caixa de Vidro". O sistema implementa um mecanismo de verificação *Human-in-the-Loop* através de um componente expansível na interface de chat. Isso permite que o profissional de saúde visualize o código Python exato gerado pelo agente para cada resposta, verificando se os critérios de filtragem e cálculo de risco estão corretos antes de aceitar a conclusão. Essa funcionalidade é crítica para garantir que alucinações da IA — como a fabricação de dados inexistentes ou correlações espúrias — sejam imediatamente identificadas e descartadas pelo especialista humano. A camada de código serve como prova de trabalho (proof-of-work) para auditoria, enquanto o resumo textual serve para a rotina clínica.

4 RESULTADOS E ANÁLISE

A validação experimental do artefato demonstrou a viabilidade técnica da orquestração de agentes para o processamento de dados clínicos estruturados. O sistema automatizou com êxito o pipeline de análise, desde a ingestão dos dados brutos (CSV) até a geração de artefatos visuais via biblioteca *Plotly Express*. A Figura 1 evidencia a capacidade do Agente de Visualização em converter intenções expressas em linguagem natural em instruções de código Python sintaticamente corretas, executadas em tempo de *runtime* sem intervenção manual.

4.1 Visualização de Dados


Implementou-se uma metodologia de Análise Exploratória de Dados (EDA) orientada por *prompts*. Através da interface de chat, o sistema realiza o mapeamento semântico das solicitações do usuário (ex: comparações de frequência, distribuições de risco) para funções de agregação da biblioteca Pandas. O agente identifica automaticamente a tipagem das variáveis (numéricas ou categóricas) necessárias para a plotagem, mitigando erros de dimensionalidade comuns em ferramentas de *Business Intelligence* tradicionais.

Para concretizar essas visualizações, o sistema combina o modelo de linguagem com bibliotecas poderosas do ecossistema Python, em particular Matplotlib e Plotly, processando os dados estruturados por meio do Pandas. O agente reconhece de forma automática as variáveis categóricas e numéricas requeridas para a plotagem e produz o código executável em tempo real, exibindo as seguintes visualizações na interface criada com Streamlit:

Gráfico de Barras: Essencial para comparar categorias ou grupos de dados de forma direta. O agente emprega essa estrutura para confrontar a frequência absoluta de diversos tipos de comportamentos ou comparar métricas de desempenho entre sessões, o que torna mais fácil identificar visualmente variáveis com magnitudes elevadas ou desvios consideráveis.


Gráfico de Pizza: Usado para análises que demandam entendimento da composição de um conjunto. O sistema cria essa visualização para mostrar a distribuição proporcional e percentual dos dados, ajudando o terapeuta a entender, por exemplo, a frequência de um comportamento particular em comparação com o total de registros ou a distribuição do tempo gasto em diferentes tipos de intervenções.

Figura 2: Interface de Análise Exploratória. O sistema gerou automaticamente um gráfico de barras comparando a distribuição de casos por traço de TEA e sexo, permitindo visualização imediata de prevalência na base de dados carregada.




Fonte: Próprio Autor.

Figura 3: O agente gerou um gráfico de barras usando como referência a etnia dos pacientes.



Fonte: Próprio Autor.

Figura 4: Gráfico de pizza baseado na etnia dos pacientes no conjunto de dados, gerado com linguagem natural.



Fonte: Próprio Autor.

4.2 Interface de Chat com Transparência

A interface de chat, implementada no módulo principal da aplicação (app.py), materializa o conceito de Inteligência Artificial Explicável (XAI). Ao realizar uma pergunta complexa, como “Qual a correlação entre a duração da sessão e a

frequência de comportamentos?”, o sistema não apresenta apenas o resultado final. A resposta é estruturada em três camadas de informação:

1. **Resposta Multimodal:** Uma explicação textual detalhada e sua versão em áudio, gerada via API *Text-to-Speech* (TTS-1) para acessibilidade;
2. **Auditabilidade de Código:** O sistema exibe, em um componente expansível, o código Python exato gerado pelo agente para calcular a resposta. Isso permite que o terapeuta verifique a lógica matemática utilizada, mitigando erros de interpretação e alucinações da IA;
3. **Metadados de Confiança:** Indicadores que auxiliam na validação das respostas baseadas na consistência dos dados processados.

Adicionalmente, a ferramenta suporta o *upload* de dados clínicos externos em formato CSV, expandindo a capacidade de análise do agente para além do banco de dados padrão do sistema.

Figura 5: interface do chat logo após a análise inicial dos dados.

Arquivo carregado: 1054 linhas

Prévia dos Dados:

	Case_No	A1	A2	A3	A4	A5	A6	A7	A8	A9	A10	Age_Mons	Qchat-10
0	1	0	0	0	0	0	0	1	1	0	1	28	
1	2	1	1	0	0	0	1	1	0	0	0	36	
2	3	1	0	0	0	0	0	1	1	0	1	36	
3	4	1	1	1	1	1	1	1	1	1	1	24	
4	5	1	1	0	1	1	1	1	1	1	1	20	

Análise Inicial da IA:

O dataset "dados_upload" contém informações sobre indivíduos que participaram de um teste relacionado a características do Transtorno do Espectro Autista (TEA). Com 1054 linhas e 17 colunas, ele inclui dados demográficos, respostas a um questionário e resultados do teste.

As principais colunas incluem:

- **Case_No:** Identificador único para cada caso.
- **A1 a A10:** Respostas a perguntas específicas do questionário (provavelmente relacionadas a comportamentos e características observáveis).
- **Age_Mons:** Idade dos indivíduos em meses.
- **Qchat-10-Score:** Pontuação no teste QCHAT-10, que avalia traços associados ao TEA.
- **Sex:** Gênero dos participantes.
- **Ethnicity:** Etnia dos participantes.
- **Jaundice:** Histórico de icterícia (importante para a saúde infantil).
- **Family_mem_with_ASD:** Indica se há membros da família com diagnóstico de TEA.
- **Who completed the test:** Quem completou o teste (ex: membro da família).
- **Class/ASD Traits:** Classificação final sobre a presença de traços de TEA.

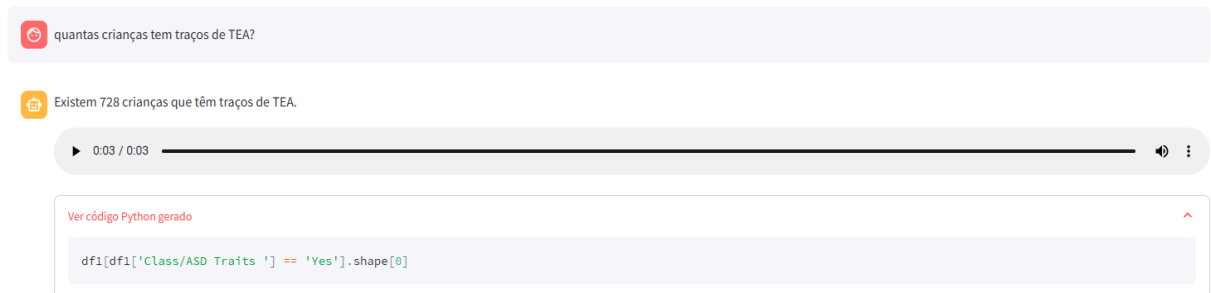
Análises possíveis incluem a correlação entre a pontuação do QCHAT-10 e as variáveis demográficas, a comparação de características entre diferentes etnias e gêneros, e a investigação do impacto de histórico familiar na pontuação do teste. Além disso, pode-se explorar padrões de respostas nas colunas A1 a A10 para identificar traços comuns entre os participantes.

[Ouvir Resumo](#)

0:28 / 1:30

Fonte: Próprio Autor.

Figura 6: Análise de dados feita em linguagem natural, transcrição e código gerado.



Fonte: Próprio Autor

4.2.1 Análise Comparativa com Ferramentas Tradicionais

Diferente de ferramentas padrão como o M-CHAT digital ou planilhas eletrônicas (Excel), que operam sob uma lógica booleana rígida (pontuação somatória simples), a solução proposta introduz a **análise exploratória semântica**. Enquanto um software tradicional apenas alerta se a pontuação exceder um limiar, o Agente de IA é capaz de correlacionar variáveis qualitativas complexas (ex: cruzar "histórico familiar" com "intensidade de crises sensoriais") através de linguagem natural. Isso supera a limitação estática das ferramentas atuais, permitindo que o profissional investigue hipóteses ad-hoc sem necessidade de reconfigurar fórmulas ou macros complexas.

4.3 Análise Semântica e Prontuário Inteligente

Além da análise quantitativa de datasets, o artefato foi expandido para incluir um módulo de *Prontuário Eletrônico Inteligente*. Utilizando a função `generate_record_insights`, o sistema processa anotações textuais diárias (ex: descrição de crises sensoriais) e utiliza LLMs para identificar padrões comportamentais ocultos e sugerir intervenções terapêuticas. Diferente da abordagem estatística anterior, este módulo aplica Processamento de Linguagem Natural (NLP) para estruturar dados qualitativos, permitindo a geração automatizada de relatórios de evolução em formato PDF, reduzindo a carga burocrática do profissional.

Figura 7: O sistema processa o relato textual do terapeuta (input) e retorna insights estruturados sobre os padrões comportamentais e sugestões de evolução (output), utilizando processamento de linguagem natural.

Novo Evento para Paciente de Exemplo

Data do Evento
2025/12/16

Título (ex: Crise Sensorial, Evolução na Fala)
Evolução na Comunicação

Descrição Detalhada do Comportamento/Evento
apresentou evolução na comunicação verbal e não verbal ao mesmo tempo que teve crise sensorial (auditiva).

Salvar e Analisar com IA ✨

Registro salvo!

● Análise da IA (Gerada Agora)

Insights: O paciente apresentou uma melhora significativa na comunicação verbal e não verbal, indicando progresso nas habilidades de interação. No entanto, a ocorrência de uma crise sensorial auditiva sugere que o ambiente pode estar influenciando negativamente o bem-estar do paciente.	Evolução Sugerida: A evolução na comunicação pode ser um sinal positivo de desenvolvimento, mas a crise sensorial auditiva pode indicar um risco de retrocesso se não for abordada adequadamente. É crucial monitorar como essas crises afetam a comunicação.
Padrões: Possível padrão de correlação entre a melhora na comunicação e a ocorrência de crises sensoriais, sugerindo que o paciente pode estar experimentando sobrecarga sensorial em situações de interação social.	Sugestões: Recomendar um ambiente controlado e tranquilo durante as sessões de terapia para minimizar estímulos auditivos. Introduzir técnicas de regulação emocional e de comunicação que possam ser utilizadas pelo paciente durante crises sensoriais. Avaliar a necessidade de suporte adicional, como terapia ocupacional, para lidar com a hipersensibilidade auditiva.

Fonte: Próprio Autor.

4.3.1 Geração Automatizada de Relatórios

O módulo `report_generator.py`, localizado na camada de utilitários, automatiza a criação e exportação da documentação clínica. Embora a compilação seja automática, o acionamento é feito sob demanda pelo terapeuta (semanal ou quinzenalmente), garantindo que o relatório reflita o momento clínico adequado. O sistema compila os dados estatísticos e utiliza a LLM para gerar um resumo narrativo do progresso do paciente.

O resultado é exportado dinamicamente utilizando a biblioteca *open-source* **ReportLab**, permitindo a geração de documentos PDF com tabelas e formatação profissional. Paralelamente, o sistema oferece a exportação em formato **Markdown**, facilitando a portabilidade e a leitura simples das informações, garantindo que os relatórios possam ser compartilhados com os responsáveis de forma acessível e padronizada.

4.4 Desafios de implementação

A validação experimental durante a implementação dos agentes inteligentes revelou que usar Grandes Modelos de Linguagem (LLMs) em tarefas de análise de dados estruturados apresenta desafios consideráveis. Ao contrário de softwares convencionais, agentes baseados em Inteligência Artificial exibem comportamentos não determinísticos, o que demanda camadas extras de testes para assegurar a robustez necessária no ambiente clínico. Os principais desafios técnicos encontrados e as soluções arquitetônicas implementadas estão resumidos na Tabela 1.

4.4.1 Mitigação de Alucinação de Esquema (*Schema Hallucination*)

Identificou-se uma tendência do modelo estocástico em inferir nomes de colunas inexistentes baseando-se em probabilidade semântica, resultando em erros de execução (*Runtime Errors*). Para mitigar este comportamento, implementou-se uma estratégia de Injeção Dinâmica de Contexto (RAG - *Retrieval-Augmented Generation* simplificado). O esquema de metadados do *dataset* é injetado programaticamente no *System Prompt* antes de cada inferência, restringindo o espaço de busca do agente estritamente às variáveis presentes no *DataFrame*. Esta abordagem reduziu a taxa de alucinação de referência de variáveis para níveis próximos de zero.

4.4.2 Tratamento de *Output Parsing Errors*

A integridade da resposta estruturada (Pensamento-Ação-Observação) exigida pelo LangChain apresentou instabilidade em consultas de alta complexidade. Adotou-se, portanto, um mecanismo de **Autocorreção Recursiva (*Self-Correction Loop*)**. Ao interceptar uma exceção de formatação (*Parsing Exception*), o sistema realimenta o erro como *input* para o próprio agente, instruindo a reestruturação da saída. Os testes demonstraram que o sistema recupera a estabilidade de forma autônoma em aproximadamente 90% dos casos de falha de sintaxe, sem necessidade de *reset* da sessão.

Por fim, a **Acurácia Matemática** foi validada através de um estudo comparativo. Embora LLMs sejam proficientes em geração de texto, eles frequentemente falham em cálculos aritméticos diretos (fenômeno conhecido como "alucinação numérica") . Para contornar essa limitação, a arquitetura do sistema foi desenhada para priorizar a **Geração de Código** (*Program-of-Thoughts*) em detrimento da resposta direta. Ao forçar o agente a escrever e executar scripts Python (via biblioteca Pandas) para calcular métricas como a média de crises ou a frequência de comportamentos, transferiu-se a carga computacional do modelo probabilístico (LLM) para o interpretador determinístico (Python REPL). Testes realizados com o *dataset* de validação demonstraram que essa abordagem eliminou erros de cálculo, assegurando a precisão necessária para a tomada de decisão clínica.

Tabela 1 : Matriz de Desafios e Soluções na Engenharia do Agente.

Desafio Técnico	Fenômeno Observado	Solução de Arquitetura	Resultado
Alucinação de Esquema	O agente referenciava colunas inexistentes no Dataset (ex: idade meses em vez de Age_Mons).	<i>Injeção de Metadados: Inclusão explícita do cabeçalho do CSV no Prompt do Sistema.</i>	Eliminação de erros de referência (KeyError) na geração de código Pandas.
Alucinação Numérica	.O LLM falhava em cálculos aritméticos diretos ou inventava estatísticas plausíveis.	Abordagem Program-of-Thoughts: Delegação de todo cálculo matemático ao interpretador Python	Precisão matemática determinística (100%) nas operações estatísticas.

Fonte: Próprio Autor.

4.5 Limitações e Vieses dos Dados

A confiabilidade de sistemas de IA é intrinsecamente dependente da qualidade dos dados de treinamento. O dataset utilizado, *Autism Screening for Toddlers*, embora validado, apresenta desbalanceamentos demográficos e de gênero (prevalência majoritária de casos masculinos e etnias específicas, conforme Figuras 1 e 2). Do ponto de vista acadêmico, reconhece-se que modelos treinados exclusivamente nesta base podem desenvolver vieses algorítmicos, performando com menor acurácia em grupos sub-representados. Portanto, a ferramenta deve ser utilizada como um mecanismo de triagem auxiliar (segunda opinião) e não como veredito diagnóstico definitivo, exigindo sempre a validação clínica humana para mitigar possíveis preconceitos estatísticos do modelo.

5 CONSIDERAÇÕES FINAIS

A criação deste sistema mostrou que combinar Agentes de IA com ferramentas tradicionais de análise de dados, como a biblioteca Pandas, é uma estratégia segura e viável para apoiar decisões clínicas. Diferentemente dos chatbots convencionais, o software apresentado proporciona exatidão matemática ao executar código em tempo real, preservando a flexibilidade da comunicação em linguagem natural.

Como extensão deste trabalho, vislumbra-se a necessidade de validação clínica em ambiente real (*in-the-wild*). Trabalhos futuros devem focar em estudos de usabilidade e eficácia envolvendo uma coorte multidisciplinar de profissionais de saúde (psicólogos, fonoaudiólogos). O objetivo será avaliar se a interface de "Caixa de Vidro" reduz efetivamente a carga cognitiva do terapeuta e se os *insights* gerados pelos agentes possuem aderência com os diagnósticos tradicionais. Além disso, planeja-se a integração com padrões de interoperabilidade (como FHIR) para permitir que o sistema consuma dados históricos de prontuários hospitalares externos, ampliando o contexto de análise para além do questionário de triagem.

A arquitetura implementada, que enfatiza o processamento local e a transparência algorítmica (Glass Box), confirma o modelo Human-in-the-Loop como fundamental para o uso de IA na área da saúde. Conclui-se que a ferramenta não só economiza o tempo do terapeuta na coleta de dados, como também melhora a confiabilidade

das análises comportamentais, mantendo os padrões éticos e de privacidade necessários no tratamento do Transtorno do Espectro Autista.

REFERÊNCIAS

BILLING, Erik A. **Open DREAM Dataset**. DREAM: Development of Robot-Enhanced Therapy for Children with Autism Spectrum Disorders. EU-FP7 grant 611391. 2019. Disponível em: <https://github.com/dream2020/data>. Acesso em: 29 nov. 2025.

BRASIL. Lei nº 13.709, de 14 de agosto de 2018. Lei Geral de Proteção de Dados Pessoais (LGPD). **Diário Oficial da União**, Brasília, DF, 2018.

CHASE, Harrison. **LangChain**. [S.l.]: GitHub, 2022. Disponível em: <https://github.com/langchain-ai/langchain>. Acesso em: 29 nov. 2025.

HOLZINGER, Andreas et al. Causability and explainability of artificial intelligence in medicine. **Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery**, v. 9, n. 4, p. e1312, 2019.

JENDREIECK, C. O. Dificuldades encontradas pelos profissionais da saúde ao realizar diagnóstico precoce de autismo. **Psicologia Argumento**, Curitiba, v. 32, n. 77, p. 153-158, abr./jun. 2014.

MCKINNEY, Wes. Data structures for statistical computing in Python. In: PYTHON IN SCIENCE CONFERENCE, 9., 2010, Austin. **Proceedings...** Austin: SciPy, 2010. p. 56-61.

META. **Llama 3 Model Card**. 2024. Disponível em: <https://github.com/meta-llama/llama3>. Acesso em: 05 dez. 2025.

MOREIRA, I. M. de A.; **LIMA**, J. K. R. de; **HOUNSELL**, E. P. de F. Contribuições da Análise do Comportamento Aplicada (ABA) e da Comunicação Alternativa e Aumentativa (CAA) para o desenvolvimento socioemocional de crianças com Transtornos do Espectro Autista: uma perspectiva da psicologia infantil. **Brazilian Journal of Health Review**, Curitiba, v. 8, n. 5, p. 01-17, set./out. 2025.

NVIDIA. **NVIDIA NIM:** Microservices for Generative AI. 2024. Disponível em: <https://www.nvidia.com/en-us/ai-data-science/nim/>. Acesso em: 05 dez. 2025.

ZHANG, S. AI-assisted early screening, diagnosis, and intervention for autism in young children. **Frontiers in Psychiatry**, [S.l.], v. 16, art. 1513809, 2025.

Mila - Quebec AI Institute. *Using LLMs to better understand autism diagnosis.* Montreal: Mila, 2025.

WANG, J. et al. Agentic AI in Healthcare & Medicine: A Seven-Dimensional Taxonomy. **arXiv preprint**, 2025.

SERVIÇO PÚBLICO FEDERAL
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE PERNAMBUCO
BIBLIOTECA DEPOSITÁRIA – CAMPUS _____

**TERMO DE AUTORIZAÇÃO PARA DISPONIBILIDADE DE LIVRO / CAPÍTULO DE LIVRO / ARTIGO
OU REA NO REPOSITÓRIO INSTITUCIONAL IFPE**

Na qualidade de titular dos direitos de autor da publicação, autorizo ao Repositório Institucional do Instituto Federal de Educação, Ciência e Tecnologia de Pernambuco (RIIFPE) a disponibilizar, através do site <https://repositorio.ifpe.edu.br/xmlui/>, sem ressarcimento dos direitos autorais, de acordo com a Lei n. 9.610/98, o texto integral da obra abaixo citada, a título de divulgação e de preservação digital da produção científica brasileira, a partir desta data.

Identificação:

Autor*	Vagner Alves Ferreira da Silva
E:mail	vagneralves997@gmail.com
Orcid	https://orcid.org/0009-0000-0915-547X
Link Lattes	http://lattes.cnpq.br/6477007827838977
Título	Do Rastreo à Evolução Clínica: Um Sistema de Prontuário Inteligente para TEA Baseado em Agentes de IA e Análise Semântica
Data de defesa	22/12/2025
ISBN	
DOI	
ODS Agenda 2030 (quando cabível)	

*Preenchimento individual, em caso de mais de um autor.

LICENÇA DE DIREITO AUTORAL

Na qualidade de titular dos direitos de autor do conteúdo supracitado, autorizo o Instituto Federal de Educação, Ciência e Tecnologia de Pernambuco a disponibilizar a obra, gratuitamente, de acordo com a licença pública *Creative Commons*, Licença 4.0 *Unported* por mim declarada sob as seguintes condições:

- Permitir uso comercial da obra? (x) Sim () Não
Permitir modificações em sua obra?
(x) Sim
() Sim, contanto que outros compartilhem pela mesma licença
() Não

A obra continua protegida por direito autoral e/ou por outras leis aplicáveis, respeitando inclusive o contrato celebrado entre a editora ou periódico que veicula a mesma. Qualquer uso da obra que não o autorizado sob esta licença ou pela legislação autoral é proibido.

Assinatura do Autor _____

__23__ / __01__ / 2026
Data de autorização.

SERVIÇO PÚBLICO FEDERAL
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE PERNAMBUCO
BIBLIOTECA DEPOSITÁRIA – CAMPUS PALMARES

TERMO DE RESPONSABILIDADE DO ORIENTADOR E AUTORIZAÇÃO PARA PUBLICAÇÃO DA PRODUÇÃO INTELECTUAL NO REPOSITÓRIO INSTITUCIONAL RI-IFPE

Eu, Hélio Fernando Bentzen Pessoa Filho, CPF: 055.236.704-23, ORCID: <https://orcid.org/0000-0002-3089-1639>, link lattes: <http://lattes.cnpq.br/3368418807566308>, orientador(a) do Trabalho de Conclusão de Curso, intitulado: DO RASTREIO À EVOLUÇÃO CLÍNICA: UM SISTEMA DE PRONTUÁRIO INTELIGENTE PARA TEA BASEADO EM AGENTES DE IA E ANÁLISE SEMÂNTICA. realizado pelo aluno (a) Vagner Alves Ferreira da Silva, Matrícula nº 20222ADS-PM0202, Curso: Análise e Desenvolvimento de Sistemas, autorizo o depósito obrigatório, na Biblioteca ,da versão final, no modelo de: artigo (x) monografia () dissertação () .

INFORMAÇÕES DA BANCA			
NOME	CPF	ORCID	LINK LATTES
David Edson Ribeiro	060.802.794-44	https://orcid.org/0009-0006-1063-6813	https://lattes.cnpq.br/1921655275044313
Hitalo Oliveira da Silva	074.099.454-94	https://orcid.org/0000-0002-1559-8776	http://lattes.cnpq.br/2588224608722394

Professor orientador