

SunflowerCare: Um Sistema Web Inteligente para Apoio ao Acompanhamento Terapêutico de Crianças com TEA

**Emanuel Dantas Filho^{1,3}, Danyllo Wagner Albuquerque^{2,3}, Ademar Sousa⁴,
Francisco Almeida Lucas^{1,3}, Karolynne Susan Freire^{1,3}, Ian Ribeiro dos Santos^{1,3}**

¹ Instituto Federal de Pernambuco (IFPE), Jaboatão dos Guararapes – PE

²Instituto Federal da Paraíba (IFPB), Campina Grande – PB

³Laboratório de Inovação em Software (LIS)

⁴Escola Estadual Rui Barbosa, Tibau – RN

{emanuel.filho, danyllo.albuquerque, ademar.sousa}@virtus.ufcg.edu.br
{KSFC, FALFJ, IRSO2}@discente.ifpe.edu.br

Resumo. O Transtorno do Espectro Autista (TEA) demanda acompanhamento contínuo e individualizado, o que torna relevante sistematizar intervenções e monitorar a evolução do paciente ao longo do tempo. Este trabalho apresenta o SunflowerCare, um sistema web que apoia o registro estruturado de sessões, a organização de atividades e o acompanhamento longitudinal do progresso de crianças com TEA. A plataforma incorpora um módulo de recomendação baseado em Machine Learning, inicialmente treinado com o dataset MMASD, para sugerir categorias de atividades alinhadas ao perfil e ao desempenho do paciente. A avaliação foi conduzida por especialistas, por meio de um instrumento baseado no Modelo de Aceitação de Tecnologia (TAM), complementado pelo julgamento clínico quanto à adequação das recomendações geradas. Os resultados indicam uma percepção positiva quanto à utilidade e à facilidade de uso do sistema, além de avaliações favoráveis quanto à pertinência terapêutica das recomendações, sugerindo a viabilidade da integração de mecanismos inteligentes em plataformas digitais de apoio ao acompanhamento terapêutico no contexto do TEA.

Abstract. Autism Spectrum Disorder (ASD) requires continuous and individualized follow-up, making it important to systematize interventions and monitor patient progress over time. This paper presents SunflowerCare, a web-based system that supports the structured recording of therapy sessions, the organization of activities, and the longitudinal monitoring of the progress of children with ASD. The platform incorporates a Machine Learning-based recommendation module, initially trained on the MMASD dataset, to suggest activity categories aligned with the child's profile and performance. The evaluation was conducted with specialists using an instrument based on the Technology Acceptance Model (TAM), complemented by clinical judgment regarding the adequacy of the generated recommendations. The results indicate positive perceptions of the system's usefulness and ease of use, as well as favorable evaluations of the therapeutic relevance of the recommendations, suggesting the feasibility of integrating intelligent mechanisms into digital platforms designed to support therapeutic follow-up.

1. Introdução

O Transtorno do Espectro Autista (TEA) é uma condição do neurodesenvolvimento caracterizada por prejuízos persistentes na comunicação e na interação social, associados a padrões restritos e repetitivos de comportamento [American Psychiatric Association 2013]. Seu acompanhamento terapêutico é complexo, contínuo e multifatorial, frequentemente envolvendo equipes multidisciplinares [Lord et al. 2020]. A natureza crônica e heterogênea do transtorno exige intervenções personalizadas, ajustes frequentes e registro sistemático da evolução ao longo do tempo. Nesse cenário, Tecnologias Assistivas (TAs) têm emergido como instrumentos para apoiar o cuidado e a tomada de decisão clínica [Preece et al. 2018].

As Tecnologias Assistivas (TAs) podem ser classificadas em cinco grupos principais: (i) Comunicação Aumentativa e Alternativa (CAA); (ii) Sistemas de Apoio à Organização (ASO); (iii) Sistemas de Linguagem e Educação (SLE); (iv) Tecnologias de Realidade Virtual e Aumentada (TRVA); e (v) Dispositivos Móveis e Embarcados (DME). Entre esses grupos, soluções do tipo ASO são particularmente relevantes por apoiarem rotinas, planejamento e organização de intervenções, complementando outras tecnologias conforme as necessidades individuais [Dantas et al. 2025].

Embora a literatura apresente avanços no uso de tecnologias digitais e TAs no acompanhamento de crianças com TEA [Sandgreen et al. 2021, Simeoli et al. 2024], muitas soluções ainda priorizam a gestão pontual de atividades, a comunicação entre atores ou o registro documental das sessões. Em particular, soluções do tipo ASO tendem a apresentar menor ênfase na integração entre monitoramento longitudinal e análise inteligente dos dados registrados. Assim, este trabalho investiga se uma solução web inteligente pode integrar registro estruturado, acompanhamento evolutivo e recomendação baseada em dados para apoiar o planejamento terapêutico de crianças com TEA.

Este trabalho apresenta o *SunflowerCare*, um sistema web para o acompanhamento terapêutico de crianças com TEA, por meio do registro estruturado e da análise longitudinal de dados. A plataforma permite o cadastro de profissionais e pacientes, o registro de sessões e intervenções e a organização de atividades em um ambiente integrado. Como diferencial, inclui um módulo de recomendação baseado em *Machine Learning* supervisionado, treinado inicialmente com o conjunto multimodal MMASD [Rahman et al. 2023] e refinado com dados coletados no próprio sistema. O objetivo é apoiar o julgamento clínico, oferecendo recomendações como subsídios para o planejamento e o ajuste de intervenções.

A avaliação foi conduzida com 12 profissionais em cenário controlado, por meio de um instrumento baseado no Modelo de Aceitação de Tecnologia (TAM) [Davis 1989] e de julgamentos clínicos sobre a pertinência das recomendações. Em síntese, as contribuições deste trabalho são: (i) uma plataforma web integrada para registro estruturado e acompanhamento longitudinal; (ii) um mecanismo de recomendação inicial treinado em dados multimodais e passível de refinamento incremental; e (iii) uma avaliação com profissionais baseada no TAM e no julgamento da pertinência das recomendações.

O artigo está estruturado da seguinte forma: a Seção 2 apresenta a fundamentação teórica e os trabalhos relacionados; a Seção 3 descreve a solução proposta; a Seção 4 detalha a metodologia; a Seção 5 apresenta os resultados; e a Seção 6 traz as considerações finais e perspectivas futuras.

2. Fundamentação Teórica e Trabalhos Relacionados

Esta seção apresenta conceitos de TEA e de TAs e discute trabalhos relacionados ao acompanhamento terapêutico apoiado por sistemas digitais.

2.1. Transtorno do Espectro Autista e Tecnologias Assistivas

O TEA é um transtorno do neurodesenvolvimento caracterizado por déficits persistentes na comunicação e na interação social, associados a padrões restritos e repetitivos [Lord et al. 2020]. Sua variabilidade clínica afeta a avaliação, a definição de metas e a seleção de estratégias de intervenção, demandando acompanhamento individualizado e ajustes contínuos [Estes et al. 2015]. Esse manejo envolve diferentes práticas terapêuticas e equipes interdisciplinares, nas quais o registro consistente e o monitoramento sistemático do progresso são centrais [Dias et al. 2024, Dawson 2010, Freres et al. 2025].

Diante dessa complexidade, as TAs têm sido incorporadas como apoio às intervenções clínicas e educacionais [Boucenna et al. 2014]. Entre suas categorias, destacam-se os Sistemas de Apoio à Organização (ASO), voltados ao planejamento de atividades, organização de rotinas e registro de intervenções [Dantas et al. 2025, Preece et al. 2018]. Por concentrarem dados de sessões e evolução, esses sistemas são candidatos naturais à integração com mecanismos analíticos de apoio à decisão.

A consolidação dessas infraestruturas digitais abre espaço para incorporar técnicas de análise de dados e aprendizado de máquina, convertendo registros clínicos em subsídios analíticos ao apoio à decisão [dos Anjos et al. 2022]. Observa-se crescimento no uso de *Machine Learning* para análise de dados comportamentais no TEA, incluindo classificação de padrões, predição de resposta a intervenções e identificação de marcadores [Mueller et al. 2021]. Contudo, tais abordagens ainda se concentram em estudos experimentais ou bases isoladas, com integração limitada a ferramentas de acompanhamento contínuo; assim, a convergência entre (i) coleta estruturada e longitudinal e (ii) recomendação inteligente permanece um desafio na prática cotidiana.

2.2. Trabalhos Relacionados

Para contextualizar a proposta, realizou-se uma busca exploratória, não sistemática, por sistemas digitais voltados ao acompanhamento terapêutico de crianças com TEA. A busca considerou termos como *Autism Spectrum Disorder*, *assistive technology*, *therapy monitoring*, *activity recommendation* e *clinical decision support*, priorizando soluções relacionadas ao registro de sessões, à organização de atividades, ao acompanhamento evolutivo ou à recomendação de intervenções.

No contexto de Sistemas de Apoio à Organização (ASO), diferentes iniciativas têm buscado apoiar a sistematização de intervenções terapêuticas. O *ABA Monitor* [Silva et al. 2020] propõe um aplicativo móvel para o registro estruturado de sessões baseado na metodologia ABA (*Applied Behavior Analysis*) [Lovaas 1987], apoiando a organização dos dados. O *TheraApp* [Oliveira et al. 2021] disponibiliza uma plataforma web voltada ao planejamento de atividades terapêuticas e à comunicação entre profissionais e familiares. Por sua vez, o *Autimo* [Souza et al. 2022] enfatiza o desenvolvimento de habilidades sociais por meio de atividades lúdicas e de recursos visuais interativos.

Embora essas soluções contribuam para a digitalização de registros e rotinas terapêuticas, elas tendem a assumir papel documental, com uso limitado do histórico longitudinal para apoiar recomendações ou ajustes de intervenção. De modo complementar, a literatura em saúde digital aponta o potencial de sistemas de suporte à decisão baseados em dados [Topol 2019, Sendak et al. 2020], mas, no contexto do TEA, aplicações de inteligência artificial ainda se concentram em bases isoladas ou tarefas específicas, com pouca integração a plataformas de uso clínico contínuo [Chen et al. 2022, Mueller et al. 2021].

Dessa forma, identifica-se uma lacuna na convergência entre três dimensões fundamentais: (i) coleta estruturada e padronizada de dados terapêuticos; (ii) monitoramento longitudinal do progresso individual; e (iii) mecanismos inteligentes de recomendação incorporados ao fluxo operacional da prática clínica. A Tabela 1 sintetiza as soluções analisadas com base nesses critérios.

Tabela 1. Comparação entre soluções e o SunflowerCare.

Solução	E	L	R
<i>ABA Monitor</i> [Silva et al. 2020]	Sim	Parcial	Não
<i>TheraApp</i> [Oliveira et al. 2021]	Sim	Parcial	Não
<i>Autimo</i> [Souza et al. 2022]	Parcial	Não	Não
SunflowerCare (este trabalho)	Sim	Sim	Sim

Nesse cenário, o *SunflowerCare* é proposto como uma abordagem integrativa que combina: (i) registro clínico estruturado (E), (ii) acompanhamento longitudinal (L) e (iii) recomendação baseada em modelagem supervisionada (R), com possibilidade de refinamento incremental a partir do uso do sistema. Ao incorporar mecanismos analíticos ao ambiente de acompanhamento terapêutico, a plataforma busca apoiar decisões clínicas com base em dados, mantendo o profissional como agente central no planejamento e ajuste das intervenções.

3. SunflowerCare

Esta seção descreve o *SunflowerCare*, a solução proposta neste trabalho para o acompanhamento terapêutico de crianças com TEA. No que segue, apresentam-se a visão geral da plataforma (Seção 3.1), suas principais funcionalidades (Seção 3.2) e a arquitetura da solução (Seção 3.3).

3.1. Visão Geral da Solução

O *SunflowerCare* é uma plataforma web projetada para apoiar o acompanhamento terapêutico de crianças com TEA por meio do registro estruturado de informações clínicas, do gerenciamento de atividades terapêuticas e do acompanhamento da evolução do paciente ao longo das sessões. A Figura 1 apresenta uma visão geral do sistema por meio de um diagrama de casos de uso.

Os casos de uso foram definidos a partir de necessidades observadas no acompanhamento terapêutico de crianças com TEA, considerando registros clínicos recorrentes, fluxos adotados por profissionais e discussões exploratórias com especialistas, preservando a autonomia clínica do terapeuta. Embora a avaliação empírica inicial tenha sido conduzida por psicólogos, a concepção da plataforma considerou a natureza multidisciplinar do acompanhamento de crianças com TEA. Por isso, funcionalidades como registro de evolução, organização de atividades e visualização longitudinal foram definidas de forma genérica, permitindo futura adaptação a outros perfis profissionais, como fonoaudiólogos, terapeutas ocupacionais e psicopedagogos.




Figura 1. Diagrama de Casos de Uso da solução SunflowerCare.

O principal ator da plataforma é o Terapeuta, que pode cadastrar pacientes, acessar recomendações, gerenciar atividades e registrar a evolução das sessões. A partir das informações clínicas e contextuais registradas, o sistema disponibiliza categorias de atividades sugeridas pelo módulo inteligente, cabendo ao profissional selecionar ou ajustar as intervenções conforme o perfil da criança e os objetivos terapêuticos.

Os dados acumulados são organizados no *dashboard*, acessível ao Terapeuta e ao Paciente ou responsável, permitindo visualizar indicadores temporais de progresso. Além disso, os registros de uso podem ampliar a base de treinamento do módulo inteligente, apoiando o refinamento futuro das recomendações.

3.2. Principais Funcionalidades

O *SunflowerCare* disponibiliza um conjunto de interfaces projetadas para apoiar a coleta estruturada de dados clínicos e a organização das intervenções terapêuticas. De forma geral, as principais funcionalidades do *SunflowerCare* são descritas a seguir:

- **Cadastro de Pacientes:** registra dados pessoais, clínicos e contextuais da criança, estruturando o perfil utilizado pelo sistema.

- **Gerenciamento de Atividades:** permite selecionar e organizar atividades terapêuticas em categorias como memorização, atenção e sequenciação lógica.
- **Registro de Progresso:** permite documentar, durante as sessões, os níveis de desempenho, os valores atingidos e as observações clínicas.
- **Dashboard Analítico:** consolida os registros em visualizações gráficas e filtros temporais, apoiando a identificação de tendências de evolução.

A Figura 2 ilustra a interface utilizada pelo terapeuta para registrar a evolução das atividades realizadas por cada paciente durante as sessões terapêuticas.



Figura 2. Interface de gerenciamento de atividades durante a sessão terapêutica, com registro de desempenho e evolução do paciente.

Esses registros alimentam o histórico do paciente e podem apoiar tanto o acompanhamento terapêutico quanto o módulo de recomendação.

3.3. Arquitetura da Solução

A arquitetura do *SunflowerCare* foi concebida segundo o modelo cliente-servidor em camadas, promovendo a separação de responsabilidades, a modularidade e a escalabilidade. A Figura 3 apresenta uma visão geral dos principais componentes da solução e de suas interações.

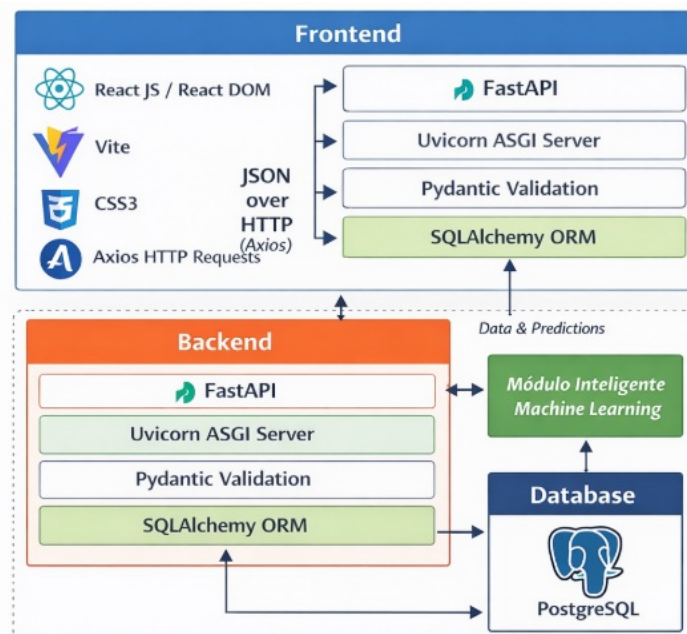


Figura 3. Arquitetura geral do *SunflowerCare*, organizada em camadas de interface, API, persistência e módulo inteligente de recomendação.

A camada de **frontend** foi desenvolvida em *React JS*, com *Vite*, *CSS3* e comunicação com a API por meio de requisições HTTP realizadas com *Axios*. A camada de **backend** foi implementada em *Python*, utilizando *FastAPI* para disponibilização da API REST, com validação de dados via *Pydantic* e execução por *Uvicorn*.

Na persistência, utiliza-se *SQLAlchemy* como ORM (*Object-Relational Mapping*) e *PostgreSQL* como banco relacional. Essa arquitetura favorece o desacoplamento entre interface, regras de negócio e persistência, facilitando manutenção e expansão futura da solução. Para fins de reprodutibilidade, um repositório de código foi disponibilizado como material complementar em versão anonimizada.¹

3.4. Módulo Inteligente de Recomendação de Atividades

O módulo inteligente do *SunflowerCare* é implementado como um componente interno da camada de *backend*, integrado às regras de negócio da API REST. Conforme descrito na Seção 3.2, o sistema registra dados estruturados sobre o perfil do paciente e o desempenho em atividades (por exemplo, níveis baixo, médio e alto), os quais são armazenados na base relacional e utilizados como variáveis de entrada no mecanismo de recomendação. Como saída, o módulo retorna a categoria de atividade recomendada para apoiar o planejamento terapêutico.

O problema é modelado como uma tarefa de classificação supervisionada, cujo objetivo é estimar a categoria de atividade mais adequada ao estado atual do paciente, com base em informações registradas no sistema. As variáveis independentes incluem histórico de desempenho e informações de uso (por exemplo, frequência e registros evolutivos), enquanto a variável-alvo corresponde à categoria de atividade recomendada.

A escolha por um modelo supervisionado, em vez de regras fixas, deve-se à variabilidade dos perfis de crianças com TEA e à relevância do histórico longitudinal de desempenho. O sistema não assume que o planejamento terapêutico siga um fluxo determinístico previamente codificável; ao contrário, considera que pacientes com características iniciais semelhantes podem responder de modo distinto às mesmas categorias de atividades. Nesse cenário, modelos supervisionados permitem incorporar padrões observados nos dados e ajustar recomendações conforme novos registros são acumulados. Ainda assim, as sugestões são tratadas como apoio ao julgamento profissional, e não como decisões automatizadas.

As recomendações são geradas no nível de categoria de atividade, associada a tipos de estimulação como atenção, memorização e sequenciação lógica. Essa decisão preserva a autonomia clínica do terapeuta, que seleciona a atividade específica conforme o contexto e as metas da sessão. Como limitação, recomendações por categoria podem reduzir a percepção de inteligência do sistema; por isso, versões futuras deverão investigar sugestões de atividades específicas, acompanhadas de justificativas e possibilidade de ajuste pelo profissional.

Foram considerados algoritmos como Árvore de Decisão (CART) [Breiman et al. 1984] e *Random Forest* [Breiman 2001], selecionados por sua adequação a dados estruturados e por oferecerem interpretabilidade, característica relevante em contextos clínicos. O pipeline envolve pré-processamento de variáveis categóricas, treinamento supervisionado e exposição das recomendações por meio de um endpoint específico da API, retornadas ao *frontend* em formato JSON.

Para mitigar o problema de inicialização (*cold start*), utilizou-se o dataset público MMASD como base de treinamento inicial [Rahman et al. 2023]. Com o uso da plataforma, os dados registrados podem compor, incrementalmente, uma base de treinamento específica do sistema, possibilitando, em ciclos posteriores, o retreinamento e o ajuste do modelo ao contexto de uso. Dessa forma, o módulo atua como um mecanismo de apoio à decisão clínica, fornecendo recomendações baseadas em dados históricos e padrões aprendidos. As sugestões geradas não substituem o julgamento profissional, mas servem como subsídios analíticos que podem auxiliar o terapeuta no planejamento e ajuste das intervenções terapêuticas.

¹<https://github.com/ANONIMO-DOUBLE-BLIND>

4. Metodologia

Esta seção descreve o delineamento metodológico adotado para avaliar o *SunflowerCare*, considerando duas Questões de Pesquisa (QP):

- **QP1:** O *SunflowerCare* é percebido como útil e fácil de usar pelos especialistas da área clínica?
- **QP2:** As recomendações geradas pelo módulo inteligente são consideradas clinicamente adequadas pelos especialistas?

A QP1 avalia a aceitação da plataforma, enquanto a QP2 analisa a adequação clínica percebida das categorias de atividades recomendadas.

4.1. Desenho da Avaliação

A Figura 4 resume o protocolo adotado na avaliação do *SunflowerCare*, desde a apresentação inicial da plataforma até a análise dos dados obtidos com os especialistas.




Figura 4. Desenho geral do protocolo de avaliação do *SunflowerCare*.

Na **Etapa 1**, o *SunflowerCare* foi apresentado aos participantes, incluindo objetivos, arquitetura e funcionalidades principais. Na **Etapa 2**, realizou-se uma demonstração prática do cadastro de pacientes, registro de atividades, consulta a recomendações e uso do *dashboard*. Na **Etapa 3**, os participantes interagiram individualmente com o sistema seguindo um roteiro de tarefas representativas. Na **Etapa 4**, responderam a um questionário com itens em escala Likert e questões abertas. Por fim, na **Etapa 5**, os dados foram analisados por estatísticas descritivas e síntese qualitativa dos comentários.

4.2. Instrumento de Avaliação

Para responder à QP1, o questionário foi estruturado com base no TAM [Davis 1989], contemplando os construtos Utilidade Percebida (UP) e Facilidade de Uso Percebida (FU). Para responder à QP2, o questionário incluiu três critérios específicos para avaliar as recomendações geradas pelo módulo inteligente: Pertinência clínica (R1), Coerência terapêutica (R2) e Potencial de evolução do paciente (R3).

Todas as questões objetivas foram avaliadas em escala Likert de 1 (discordo totalmente) a 5 (concordo totalmente). Comentários abertos foram coletados para complementar a interpretação dos resultados. As estatísticas (média, mediana e desvio-padrão) foram calculadas diretamente a partir das respostas dos participantes para cada item.

Tabela 2. Itens do instrumento.

ID	Afirmação
PU	O sistema pode apoiar minha eficiência ao planejar/registrar sessões terapêuticas.
FU	Considero o sistema fácil de aprender a usar.
R1	As recomendações são clinicamente pertinentes ao perfil analisado.
R2	As recomendações são coerentes com o planejamento terapêutico esperado.
R3	As recomendações têm potencial de contribuir para a evolução do paciente.

Optou-se por um instrumento enxuto, com uma pergunta por constructo (PU e FU) e uma pergunta por critério da QP2 (R1–R3), visando reduzir o tempo de aplicação; consequentemente, a avaliação tem caráter exploratório. O instrumento completo e as respostas anonimizadas (por participante) foram disponibilizados como material suplementar, em versão anonimizada, para fins de transparência e reprodutibilidade durante a avaliação por pares.²

²Material suplementar anonimizado disponível em: <https://anonimo-link-publicacao>

4.3. Participantes

Participaram da avaliação 12 psicólogos com experiência clínica no atendimento a crianças com TEA. O grupo foi composto por 8 mulheres e 4 homens, com uma média de 3 anos de experiência profissional. Todos os participantes relataram atuação ativa na Terapia Cognitivo-Comportamental (TCC), abordagem amplamente utilizada no acompanhamento terapêutico de indivíduos com TEA. Esse perfil contribui para a adequação dos avaliadores ao contexto de uso previsto para a plataforma. Antes da participação no estudo, todos os voluntários foram informados sobre os objetivos da pesquisa e concordaram em participar mediante assinatura do Termo de Consentimento Livre e Esclarecido (TCLE). Os dados coletados foram utilizados exclusivamente para fins de pesquisa e analisados de forma anonimizada.

5. Resultados e Discussão

Esta seção apresenta os resultados da avaliação empírica do *SunflowerCare*, organizada conforme as duas QPs definidas na Seção 4. A coleta de dados foi realizada entre fevereiro e março de 2026, em sessões conduzidas em ambiente controlado com os participantes do estudo.

5.1. Aceitação do Sistema (QP1)

Para responder à QP1 (i.e., avaliar se o *SunflowerCare* é percebido como útil e fácil de usar), foram analisadas as respostas ao instrumento baseado no modelo TAM. A Tabela 3 apresenta as estatísticas descritivas obtidas para cada item (PU e FU), calculadas a partir das respostas dos 12 participantes em escala Likert de 1 a 5. Assim, os valores de média, mediana e desvio-padrão referem-se à distribuição dessas 12 respostas por item, conforme descrito na Seção 4.

Tabela 3. Resultados descritivos da avaliação baseada no TAM.

Constructo (item)	Média	Mediana	Desvio Padrão
Utilidade Percebida (UP)	4,6	5	0,48
Facilidade de Uso (FU)	4,4	4	0,52

O Constructo *Utilidade Percebida* (UP) apresentou média de 4,6, sugerindo que os participantes perceberam potencial de valor prático na utilização da plataforma para apoiar o planejamento e o acompanhamento das intervenções terapêuticas. Esse resultado indica que os especialistas percebem o sistema como potencialmente útil no contexto de suas práticas profissionais.

O Constructo *Facilidade de Uso* (FU) apresentou média de 4,4 e desvio padrão reduzido, indicando que os participantes consideraram a interação com o sistema relativamente simples e intuitiva. Esse resultado sugere que a interface e o fluxo de uso da plataforma não representaram barreiras significativas para os profissionais avaliadores.

Os comentários qualitativos reforçaram esses resultados, com menções recorrentes à organização das informações, à visualização longitudinal da evolução e à integração entre o registro e a recomendação. Por exemplo, participantes relataram: “*Diferente de outras ferramentas, com essa abordagem podemos centralizar não apenas informações gerenciais, mas também terapêuticas*” e “*Tenho que fazer muitos relatórios durante o ano; com o dashboard, consigo ver com mais clareza em que aspectos o paciente evoluiu.*”.

Resposta à QP1

Os resultados indicam que o *SunflowerCare* foi percebido pelos especialistas como uma ferramenta útil e de fácil uso. As médias observadas em Utilidade Percebida (UP = 4,6) e Facilidade de Uso (FU = 4,4) sugerem uma aceitação positiva da plataforma no contexto de apoio ao acompanhamento terapêutico.

5.2. Avaliação das Recomendações (QP2)

Para responder à QP2 (i.e., avaliar se as recomendações geradas são clinicamente adequadas), os especialistas avaliaram recomendações produzidas pelo módulo inteligente por meio de três afirmações (R1–R3), uma por critério: pertinência clínica, coerência terapêutica e potencial de evolução. A Tabela 4 apresenta os resultados descritivos.

Tabela 4. Avaliação das recomendações por especialistas.

Critério (item)	Média	Mediana	Desvio Padrão
Pertinência Clínica (R1)	4,5	5	0,50
Coerência Terapêutica (R2)	4,3	4	0,55
Potencial de Evolução (R3)	4,6	5	0,49

O critério *Pertinência Clínica* apresentou média de 4,5, sugerindo que os especialistas consideraram as recomendações adequadas ao perfil terapêutico dos pacientes apresentados no cenário de avaliação. Esse resultado indica que as sugestões fornecidas pelo sistema foram percebidas como compatíveis com práticas clínicas reconhecidas.

O critério *Coerência Terapêutica* apresentou média de 4,3, valor ligeiramente inferior aos demais, mas ainda dentro de uma faixa elevada de concordância. Esse resultado indica que, embora as recomendações sejam consideradas adequadas, pode haver espaço para aprimorar o alinhamento entre as sugestões geradas pelo sistema e as estratégias terapêuticas específicas adotadas pelos profissionais.

O critério *Potencial de Evolução* apresentou a maior média entre os itens avaliados (4,6), indicando que os especialistas consideraram as atividades recomendadas potencialmente úteis para promover avanços no desenvolvimento dos pacientes. Esse resultado sugere que as recomendações são coerentes com o contexto clínico e também podem contribuir para orientar intervenções com impacto positivo no progresso terapêutico.

A análise qualitativa dos comentários abertos reforça os resultados quantitativos observados. Alguns participantes destacaram a utilidade das recomendações como apoio ao planejamento das atividades terapêuticas. Por exemplo, um especialista relatou: *“As sugestões fazem sentido dentro do perfil apresentado e podem ajudar a orientar a escolha de atividades, principalmente em fases iniciais do planejamento terapêutico.”* Outro participante destacou que *“o sistema pode ser útil como um ponto de partida para selecionar atividades, especialmente quando há muitos aspectos do desenvolvimento a considerar.”*

Também foram apontadas observações relacionadas ao contexto de treinamento do modelo. Alguns participantes observaram que o desempenho percebido do módulo tende a ser mais consistente quando os perfis avaliados se aproximam dos padrões representados no dataset MMASD utilizado no pré-treinamento. Nesse sentido, um especialista comentou: *“As recomendações parecem mais consistentes quando o perfil do paciente se aproxima daqueles já observados no sistema.”*

Além disso, alguns participantes sugeriram a ampliação do repertório de categorias terapêuticas disponíveis. Conforme relatado por um dos especialistas: *“Consegui inserir todas as atividades que utilizo atualmente, porém profissionais menos experientes podem ter dificuldades para selecionar atividades adequadas sem um repertório mais amplo.”* Outro comentário destacou que *“quanto maior a variedade de categorias e exemplos de atividades, maior tende a ser a utilidade prática do sistema.”*

Essas observações qualitativas sugerem que o desempenho do módulo inteligente pode ser aprimorado por meio da expansão da base de dados utilizada no treinamento e da ampliação do conjunto de categorias terapêuticas disponíveis na plataforma.

Resposta à QP2

Os resultados indicam que as recomendações geradas foram consideradas clinicamente adequadas pelos especialistas participantes. As médias elevadas observadas nos critérios de pertinência clínica (4,5), coerência terapêutica (4,3) e potencial de evolução (4,6) sugerem que as sugestões fornecidas pelo sistema são percebidas como relevantes para apoiar o planejamento de intervenções terapêuticas.

5.3. Implicações

Os resultados deste estudo apresentam algumas implicações relevantes para o uso de tecnologias digitais no acompanhamento terapêutico de crianças com TEA. Primeiramente, os resultados associados à QP1 indicam que especialistas percebem valor prático na utilização do *SunflowerCare* como ferramenta de apoio ao planejamento e ao acompanhamento das intervenções terapêuticas. Isso sugere que plataformas digitais que integram registro estruturado de sessões e visualização da evolução do paciente podem contribuir para melhorar a organização das informações clínicas e apoiar o processo de tomada de decisão dos profissionais.

Em segundo lugar, os resultados relacionados à QP2 indicam que a incorporação de mecanismos de recomendação baseados em aprendizado de máquina pode ser considerada útil no contexto clínico, desde que mantenha o profissional como agente central no processo terapêutico. Nesse sentido, sistemas inteligentes podem atuar como instrumentos de apoio à decisão, fornecendo sugestões baseadas em padrões observados em dados históricos.

Por fim, os comentários qualitativos obtidos no estudo sugerem que o potencial de sistemas dessa natureza pode ser ampliado por meio da expansão da base de dados utilizada no treinamento dos modelos e da ampliação do repertório de atividades terapêuticas disponíveis na plataforma.

6. Considerações Finais

Este trabalho apresentou o *SunflowerCare*, um sistema web para acompanhamento terapêutico de crianças com Transtorno do Espectro Autista (TEA), integrando registro estruturado de sessões, visualização longitudinal de progresso e recomendação de categorias de atividades.

A avaliação empírica, orientada por duas questões de pesquisa, indicou percepção positiva quanto à utilidade percebida e à facilidade de uso da plataforma, bem como avaliação favorável da pertinência e coerência clínica das recomendações. Os achados sugerem a viabilidade inicial de integrar aprendizado de máquina a uma plataforma clínica estruturada, mantendo o profissional como agente central do planejamento terapêutico. Em síntese, o trabalho contribui com: (i) uma plataforma web integrada para registro e acompanhamento longitudinal; (ii) um mecanismo de recomendação supervisionado, com possibilidade de evolução a partir dos dados de uso; e (iii) uma avaliação exploratória com especialistas, combinando aceitação tecnológica e julgamento clínico das recomendações.

Entretanto, este estudo apresenta limitações que devem ser consideradas. A amostra foi reduzida e composta apenas por psicólogos que atuam com Terapia Cognitivo-Comportamental (TCC), o que limita a generalização dos resultados para outros perfis profissionais e abordagens. Parte do treinamento inicial do módulo inteligente utilizou o dataset MMASD, que pode não refletir a total diversidade de perfis clínicos da prática real. Além disso, a avaliação ocorreu em ambiente controlado, sem grupo de controle nem comparação direta com métodos tradicionais, como registros em papel ou sistemas digitais sem recursos inteligentes. Assim, os resultados devem ser interpretados como evidências iniciais de aceitação e adequação percebida, e não como comprovação objetiva de ganho de eficiência.

Como trabalhos futuros, destacam-se: (i) ampliação da base de dados com registros reais coletados na própria plataforma; (ii) inclusão de profissionais de outras áreas terapêuticas, como Fonoaudiologia, Terapia Ocupacional e Psicopedagogia; (iii) realização de estudos longitudinais em contexto real de uso; e (iv) investigação de estratégias de evolução contínua do modelo de recomendação. Essas etapas futuras são necessárias para consolidar a efetividade, a abrangência e a aplicabilidade do *SunflowerCare* em contextos reais de acompanhamento terapêutico.

Referências

- American Psychiatric Association (2013). *Diagnostic and Statistical Manual of Mental Disorders (DSM-5)*. American Psychiatric Publishing, Washington, DC.
- Boucenna, S. et al. (2014). Interactive technologies for autistic children: A review. *Cognitive Computation*, 6(4):722–740.
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1):5–32.
- Breiman, L., Friedman, J., Stone, C. J., and Olshen, R. A. (1984). *Classification and Regression Trees*. Wadsworth International Group, Belmont, CA.
- Chen, Z. S., Galatzer-Levy, I. R., Bigio, B., Nasca, C., Zhang, Y., et al. (2022). Modern views of machine learning for precision psychiatry. *Patterns*, 3(11).
- Dantas, E., Albuquerque, D., Neto, A. S., Fonseca, A. V., and Rocha, I. M. (2025). Uma revisao da literatura sobre tecnologias assistivas para apoiar estudantes com tea no ensino superior. In *Workshop sobre Educação em Computação (WEI)*, pages 113–124. SBC.
- Davis, F. D. (1989). Perceived usefulness, perceived ease of use, and user acceptance of information technology. *MIS Quarterly*, 13(3):319–340.
- Dawson, G. (2010). Early behavioral intervention, brain plasticity, and the prevention of autism spectrum disorder. *Development and Psychopathology*, 20(3):775–803.
- Dias, J. L. B., Martins, M. P. B., Coelho, L. F., da Silva, P. H. C. L., de Lima, T. d. S. B., de Faria, I. A. F. K., Maggi, F., de Sá Oliveira, L. D., de Souza Silva, I. A., Cutrim, D. M., et al. (2024). Intervenções terapêuticas multimodais no transtorno do espectro autista: Impactos no desenvolvimento cognitivo e social. *Revista Ibero-Americana de Humanidades, Ciências e Educação*, 10(12):2285–2295.
- dos Anjos, F. M., Oliveira, L. W., Souza, C. H. R., and Carvalho, S. T. (2022). Aplicações de técnicas de machine learning e gamificação no autocuidado em saúde: Uma revisão sistêmica. *Simpósio Brasileiro de Jogos e Entretenimento Digital (SBGames)*, pages 1376–1380.
- Estes, A. et al. (2015). Long-term outcomes of early intervention in 6-year-old children with autism spectrum disorder. *Journal of the American Academy of Child Adolescent Psychiatry*, 54(7):580–587.
- Freres, S. C., Batista, I. B. M., Antônio, E. R., Brilhante, D. F. M., Brilhante, D. F. M., Carneiro, I. C., de Castro Roveda, P., Franchi, A. P. A., Haddad, F. H., da Silva, L. A., et al. (2025). Transtorno do espectro autista: Aspectos clínicos, diagnósticos e abordagens terapêuticas atuais. *Brazilian Journal of Implantology and Health Sciences*, 7(12):563–574.
- Lord, C., Elsabbagh, M., Baird, G., and Veenstra-Vanderweele, J. (2020). Autism spectrum disorder. *The Lancet*, 392(10146):508–520.
- Lovaas, O. I. (1987). Behavioral treatment and normal educational and intellectual functioning in young autistic children. *Journal of Consulting and Clinical Psychology*, 55(1):3–9.
- Mueller, S. et al. (2021). Machine learning in autism spectrum disorder: a systematic review. *NeuroImage: Clinical*, 31:102708.
- Oliveira, J. S., Almeida, T. P., and Gomes, A. C. (2021). Theraapp: plataforma web para gerenciamento de atividades terapêuticas de crianças com tea. In *Anais do XLVII SEMISH*, Brasília, DF. SBC.
- Preece, J., Sharp, H., and Rogers, Y. (2018). *Assistive Technology: Principles and Applications for Communication and Learning*. Springer, Cham, Switzerland.
- Rahman, M., Kwon, J., Williams, E., Pagan, S., et al. (2023). MMASD: A Multimodal Dataset for Autism Therapy and Assessment. *arXiv preprint arXiv:2306.08243*.

- Sandgreen, H., Frederiksen, L. H., and Bilenberg, N. (2021). Digital interventions for autism spectrum disorder: A meta-analysis. *Journal of Autism and Developmental Disorders*, 51(9):3138–3152.
- Sendak, M. P. et al. (2020). A path for translation of machine learning products into healthcare delivery. *EMJ Innovations*, 4(1):23–29.
- Silva, R. P., Lima, M. A., and Souza, L. F. (2020). Aba monitor: aplicação móvel para registro e acompanhamento terapêutico de crianças com tea. In *Anais do XLVI SEMISH*, Porto Alegre, RS. SBC.
- Simeoli, R., Rega, A., Cerasuolo, M., Nappo, R., and Marocco, D. (2024). Using machine learning for motion analysis to early detect autism spectrum disorder: A systematic review. *Review Journal of Autism and Developmental Disorders*, pages 1–20.
- Souza, C. M., Rodrigues, F. B., and Pereira, L. N. (2022). Autimo: aplicativo lúdico para o desenvolvimento de habilidades sociais em crianças com tea. In *Anais do XLVIII SEMISH*, Niterói, RJ. SBC.
- Topol, E. (2019). High-performance medicine: the convergence of human and artificial intelligence. *Nature Medicine*, 25:44–56.