

NeuroIA: Inteligência Artificial Aplicada ao Suporte Terapêutico de Crianças Neurodivergentes

Rafael Mateus de Lima¹, Kevin V. Pires dos Santos¹, Evandro F. Silva¹, Bruno C. Gevehr Pawlak¹,

¹Faculdade Donaduzzi
Av. Max Planck, s/n – Biopark – Toledo – PR – Brasil

Rafaelmlima201@gmail.com

Abstract. *This paper presents NeuroIA, a technological system designed to support therapists in the clinical follow-up of neurodivergent children. The solution integrates Retrieval-Augmented Generation (RAG) with Large Language Models (LLMs) for generating personalized therapeutic recommendations and clinical reports, alongside a development regression detection module that combines linear regression trend analysis and the Isolation Forest algorithm. Monte Carlo simulation experiments with 200 iterations per scenario yielded a True Positive Rate of 97.5% for severe decline cases and a False Positive Rate of 2.3% for stable cases, both within the 5% significance level. All processes comply with the Brazilian General Data Protection Law (LGPD), keeping the human professional central to every clinical decision.*

Resumo. *Este trabalho apresenta o NeuroIA, um sistema tecnológico desenvolvido para apoiar terapeutas no acompanhamento clínico de crianças neurodivergentes. A solução integra Retrieval-Augmented Generation (RAG) com Large Language Models (LLMs) para geração de recomendações terapêuticas personalizadas e relatórios clínicos, além de um módulo de detecção de regressão que combina análise de tendência por regressão linear e o algoritmo Isolation Forest. Experimentos de simulação Monte Carlo com 200 iterações por cenário evidenciaram Taxa de Verdadeiro Positivo de 97,5% para declínios severos e Taxa de Falso Positivo de 2,3% em casos estáveis, ambos dentro do nível de significância de 5%. Todos os processos estão em conformidade com a LGPD, mantendo o profissional humano no centro de cada decisão clínica.*

1. Contextualização do Problema

A neurodivergência, termo que abrange condições como o Transtorno do Espectro Autista (TEA) e o Transtorno do Déficit de Atenção com Hiperatividade (TDAH), afeta uma parcela significativa da população infantil brasileira. Dados do Censo Demográfico 2022, divulgados pelo IBGE [1], revelam que 2,6% das crianças de 5 a 9 anos receberam diagnóstico de TEA, totalizando 2,4 milhões de pessoas no espectro. A demanda por acompanhamento especializado supera consideravelmente a capacidade dos serviços disponíveis, especialmente em municípios de médio e pequeno porte.

O acompanhamento terapêutico eficaz exige monitoramento contínuo do desenvolvimento, elaboração periódica de relatórios clínicos e recomendações individualizadas baseadas em evidências. Esses processos são intensivos em tempo profissional, sujeitos à variabilidade entre avaliadores e de difícil escalabilidade. A identificação tardia de regressões em habilidades adquiridas é particularmente crítica, pois pode atrasar

intervenções que, quanto mais precoces, produzem melhores desfechos clínicos. O uso de inteligência artificial como ferramenta de apoio ao terapeuta, sem substituí-lo, representa uma oportunidade concreta de ampliar a consistência e rastreabilidade das decisões terapêuticas [2].

2. Descrição da Solução Tecnológica

O NeuroIA é um sistema composto por três módulos integrados. A Figura 1 descreve o fluxo completo, da entrada do perfil clínico do paciente às saídas entregues ao terapeuta.




Figura 1. Fluxo completo do NeuroIA. O Módulo RAG (topo) gera recomendações via GPT-4 com validação de segurança. O Detector de Regressão (meio) combina regressão linear e Isolation Forest para emitir alertas. O Gerador de Relatórios (base) produz sumários e análises entregues ao profissional.

Módulo RAG para Recomendações Terapêuticas

- A partir do perfil estruturado do paciente, o sistema gera uma representação semântica via *embedding* e realiza busca vetorial na base de conhecimento clínico, recuperando os conteúdos mais relevantes.
- Esses conteúdos são usados como contexto para que o *GPT-4* [3] gere recomendações personalizadas e fundamentadas em evidências.
- Toda saída passa por um *safety gate* que bloqueia afirmações absolutas ou recomendações fora do escopo clínico autorizado.

Módulo de Geração de Relatórios Clínicos

- Produz automaticamente sumários executivos, análises de progresso longitudinal e recomendações estruturadas.
- As saídas são registradas em formato padronizado com trilha de auditoria completa, garantindo rastreabilidade de cada registro.

Módulo de Detecção de Regressão

- A regressão linear analisa a tendência temporal dos indicadores, identificando trajetórias de declínio ao longo do tempo.
- O *Isolation Forest* [4] detecta pontos anômalos na série temporal: quanto menor o caminho para isolar um ponto, maior sua probabilidade de ser uma anomalia.
- A combinação gera um escore de risco agregado que aciona alerta ao terapeuta quando ultrapassa o limiar configurável.

Em todos os módulos, nenhuma ação clínica é autônoma: o profissional humano valida e aceita explicitamente cada saída do sistema.

3. Ferramentas e Tecnologias Utilizadas

O *backend* foi desenvolvido em *Python* com *FastAPI*. A camada de IA utiliza *GPT-4* para geração de recomendações e relatórios, e *text-embedding-ada-002* para representação semântica. A busca vetorial opera no *Chroma* com *top_k* = 5, *chunk_size* = 1000 e *chunk_overlap* = 200. O módulo de detecção combina regressão linear sobre séries temporais de quatro variáveis clínicas – comunicação, motricidade, interação social e autorregulação – com *Isolation Forest* (*n_estimators* = 100, limiar de contaminação configurável por perfil), ambos via *scikit-learn* [5]. A avaliação usou Monte Carlo (*N* = 200 por cenário), IC 95% via *bootstrap* com 1.000 reamostras e testes binomiais unilaterais.

4. Resultados Práticos Obtidos

4.1. Validação Automatizada

A suíte de testes automatizados contou com 18 casos de teste, todos aprovados, cobrindo os principais comportamentos esperados do detector em situações controladas, com tempo de execução inferior a três segundos.

4.2. Benchmark Monte Carlo do Detector

O benchmark avaliou o detector em quatro cenários distintos. A Tabela 1 apresenta os resultados obtidos.

Tabela 1. Resultados da simulação Monte Carlo por cenário (*N* = 200)

Cenário	Métrica	Valor	IC 95%	Sig.
Estável	FPR	2,3%	—	5%
Melhorando	FPR	1,8%	—	—
Declínio forte	TPR	97,5%	—	5%
Declínio leve	TPR	64,5%	[57,5%; 71,0%]	—

O sistema demonstrou desempenho clinicamente relevante: alta taxa de detecção de declínios severos com baixo índice de falsos alarmes em casos estáveis. A confiança média das predições foi de 60,9% nos cenários de declínio severo contra 49,7% nos casos estáveis, evidenciando separação estatística consistente e confirmando que o modelo discrimina situações críticas das normais. Para os casos de declínio leve, a taxa de 64,5% reflete o caráter gradual e multifatorial dessas quedas; a calibração de limiares por faixa etária e tipo de neurodivergência é a principal alavanca para elevar esse indicador.

4.3. Comparação com Abordagens Alternativas

O diferencial do NeuroIA manifesta-se em três aspectos. Primeiro, LLMs sem RAG produzem recomendações descontextualizadas do histórico do paciente; o NeuroIA ancora cada geração no perfil clínico recuperado. Segundo, detectores de anomalia isolados (*Isolation Forest* puro) têm sensibilidade reduzida a declínios graduais; a combinação com regressão linear cobre esse espectro. Terceiro, implementações diretas de LLM em saúde raramente incluem *safety gates* automáticos de linguagem diagnóstica. A contribuição científica está, portanto, não nas tecnologias individualmente, mas na arquitetura integrada com mecanismos de segurança clínica projetados especificamente para o contexto de neurodivergência pediátrica.

4.4. Comportamento do Módulo RAG

Os testes de integração confirmaram o funcionamento correto em todas as etapas: geração de *embeddings*, recuperação vetorial e geração com contexto clínico [2]. O *safety gate* bloqueou corretamente saídas com afirmações absolutas ou recomendações fora do escopo. Quando o contexto recuperado era insuficiente, o modelo declarou incerteza explicitamente, ao invés de inferir sem evidências – comportamento essencial para a segurança clínica do sistema.

5. Lições Aprendidas

Combinação de técnicas é mais robusta: A integração da regressão linear com o *Isolation Forest* mostrou-se mais eficaz do que qualquer método isolado: a regressão captura tendências contínuas de declínio, enquanto o *Isolation Forest* detecta quedas abruptas, cobrindo um espectro maior de padrões clínicos.

O contexto recuperado determina a qualidade do RAG: A pertinência clínica das recomendações depende diretamente da base de conhecimento indexada. Sem contexto adequado, as saídas tornam-se genéricas e menos seguras, tornando a curadoria contínua da base vetorial uma atividade permanente.

Limitações e vieses a considerar: Os experimentos foram conduzidos com dados sintéticos, o que limita a generalização para populações clínicas reais. A validação com dados reais ainda não foi realizada por razões práticas e éticas: o uso de dados clínicos de crianças requer aprovação de Comitê de Ética em Pesquisa, cujo processo está em andamento; o recrutamento de participantes demanda suporte clínico ainda não disponível; e a plataforma permanece em desenvolvimento. O detector também não foi estratificado por faixa etária ou tipo de neurodivergência, variáveis que podem alterar os limiares ótimos.

LGPD como diretriz de arquitetura: O tratamento de dados de crianças neurodivergentes, categoria sensível prevista na Lei nº 13.709/2018 [7], orientou decisões de projeto desde o início: anonimização de identificadores, consentimento dos responsáveis legais e trilha de auditoria são requisitos estruturais. Como próximos passos, o sistema aguarda validação com dados reais por especialistas em dupla avaliação cega, estudo A/B de variantes de prompt e submissão ao Comitê de Ética para estudo prospectivo em ambiente terapêutico real.

Referências

- [1] Instituto Brasileiro de Geografia e Estatística – IBGE (2025). *Censo Demográfico 2022: Pessoas com Deficiência e Pessoas Diagnosticadas com Transtorno do Espectro Autista – Resultados Preliminares da Amostra*. Rio de Janeiro: IBGE. Disponível em: <https://agenciadenoticias.ibge.gov.br/agencia-noticias/2012-agencia-de-noticias/noticias/43464>. Acesso em: abr. 2026.
- [2] Lewis, P., Perez, E., Piktus, A., Petroni, F., Karpukhin, V., Goyal, N., Küttler, H., Lewis, M., Yih, W., Rocktäschel, T., Riedel, S., Kiela, D. (2020). Retrieval-Augmented Generation for Knowledge-Intensive NLP Tasks. *Advances in Neural Information Processing Systems (NeurIPS)*, 33, pp. 9459–9474. Disponível em: <https://proceedings.neurips.cc/paper/2020/hash/6b493230205f780e1bc26945df7481e5-Abstract.html>.
- [3] OpenAI (2023). GPT-4 Technical Report. *arXiv preprint arXiv:2303.08774*. DOI: <https://doi.org/10.48550/arXiv.2303.08774>.
- [4] Liu, F. T., Ting, K. M., Zhou, Z.-H. (2008). Isolation Forest. *Proceedings of the 8th IEEE International Conference on Data Mining (ICDM 2008)*, Pisa, Itália, pp. 413–422. DOI: <https://doi.org/10.1109/ICDM.2008.17>.
- [5] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., Duchesnay, E. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12, pp. 2825–2830. Disponível em: <https://jmlr.org/papers/v12/pedregosa11a.html>.
- [6] Harrison, R. L. (2010). Introduction to Monte Carlo Simulation. *AIP Conference Proceedings*, 1204(1), pp. 17–21. DOI: <https://doi.org/10.1063/1.3295638>.
- [7] Brasil (2018). *Lei nº 13.709, de 14 de agosto de 2018 – Lei Geral de Proteção de Dados Pessoais (LGPD)*. Diário Oficial da União, Brasília, DF, 15 ago. 2018. Disponível em: https://www.planalto.gov.br/ccivil_03/_ato2015-2018/2018/lei/l13709.htm.