

CogniKids: Sinergia entre IoT e Inteligência Artificial para o Suporte Colaborativo Família-Escola na Educação Inclusiva

Maria Clara Ribeiro Di Bragança¹, Frederico Lemes Rosa^{1,2},
Willgner Ferreira Santos^{1,2} e Alisson Rodrigues Alves¹

¹ Faculdade SENAI Fatesg
R. 227-A, 95 – Setor Leste Universitário, Goiânia – GO, 74610-155

² Faculdade SENAI Fatesg – Núcleo de Inteligência Artificial Aplicada – NIAA

{mclara.braganca, frederico.lemesrosa}@gmail.com
{willgnerferreira, alissonalves.senai}@fieg.com.br

Abstract. *This paper evaluates the technical feasibility of CogniKids, a pervasive IoT Proof of Concept for continuous emotional monitoring of neurodivergent students. Following the Ubiquitous Computing paradigm, the system employs a distributed event-driven architecture with unobtrusive wearable sensors and Machine Learning for context-aware crisis detection. Due to ethical restrictions involving minors, validation was performed in a stochastic simulation using synthetic data derived from medical literature. The Random Forest model achieved 85% accuracy and 84% recall, while the backend maintained 50,27 ms average latency with 50,000 records.*

Resumo. *Este artigo avalia a viabilidade técnica do CogniKids, uma Prova de Conceito baseada em IoT pervasiva para o monitoramento contínuo de estados emocionais de estudantes neurodivergentes. Fundamentado no paradigma da Computação Ubíqua, o sistema utiliza uma arquitetura distribuída orientada a eventos, com sensores vestíveis não intrusivos e Aprendizado de Máquina para detecção contextualizada de crises. Devido a restrições éticas envolvendo menores, a validação foi realizada em ambiente de simulação estocástica com dados sintéticos derivados da literatura médica. O modelo Random Forest obteve 85% de acurácia e 84% de revocação, enquanto o backend manteve latência média de 50,27 ms com 50,000 registros.*

1. Introdução

A educação inclusiva consolida-se como um direito fundamental, alicerçado em diretrizes nacionais, como a Lei de Diretrizes e Bases da Educação (LDB) [Brasil 1996], e marcos internacionais, como a Declaração de Salamanca [UNESCO 1994]. Entretanto, a materialização desse direito enfrenta barreiras críticas de escalabilidade diante da demanda crescente. Dados recentes indicam um aumento de 44,4% nas matrículas de estudantes com Transtorno do Espectro Autista (TEA) na educação básica entre 2023 e 2024 [MEC 2024]. Essa expansão pressiona uma infraestrutura pedagógica já desafiada por elevados índices de distorção idade-série, frequentemente correlacionados à ausência de diagnóstico e suporte tempestivo a transtornos do neurodesenvolvimento no ambiente escolar [Hoffmann et al. 2023, FAPESP 2021].

A lacuna entre a necessidade de inclusão e a capacidade de suporte individualizado resulta em custos sociais elevados, onde déficits na regulação emocional e sobrecargas sensoriais muitas vezes imperceptíveis à observação humana direta culminam em crises de desregulação e desengajamento. Nesse cenário, a literatura recente aponta que sinais fisiológicos, como frequência cardíaca e condutância eletrotérmica, oferecem janelas de oportunidade para a predição de comportamentos agressivos e crises, superando a latência da intervenção reativa [Imbiriba et al. 2023, Emezie et al. 2024]. Contudo, ainda observa-se na literatura a ausência de modelos arquiteturais que integrem efetivamente esse monitoramento biométrico a um fluxo de resposta pedagógica imediata.

É nesse contexto que o paradigma da Computação Ubíqua, concebido por Mark Weiser [Weiser 1991], revela seu potencial transformador: tecnologia que se dissolve no ambiente escolar e serve às pessoas sem exigir sua atenção consciente. O conceito complementar de *calm technology* [Weiser and Brown 1996] fundamenta o design do CogniKids, propondo um ecossistema pervasivo capaz de monitorar estados emocionais de estudantes neurodivergentes sem interromper o fluxo natural da aula.

Diante desse contexto, este trabalho investiga a seguinte questão de pesquisa: *Qual a viabilidade técnica de uma arquitetura pervasiva IoT distribuída com Machine Learning para detecção contínua e transparente de padrões emocionais em dados biométricos sintéticos, visando fundamentar futuros sistemas de suporte à educação inclusiva?*

O objetivo geral deste estudo é propor e validar tecnicamente o **CogniKids**, uma Prova de Conceito (PoC) de um ecossistema ubíquo unificado para monitoramento de estados emocionais. Especificamente, o trabalho visa: (i) desenvolver uma arquitetura híbrida resiliente à heterogeneidade de hardware, operando de forma transparente no ambiente escolar; (ii) implementar um modelo de *Machine Learning* (Random Forest) capaz de detectar crises simuladas com alta sensibilidade, habilitando resposta em tempo real; e (iii) estruturar um *dashboard* de visualização sensível ao contexto para apoio à decisão docente. A principal contribuição científica deste artigo reside na demonstração de viabilidade técnica e arquitetural de um sistema pervasivo de baixo custo e alta disponibilidade, capaz de instrumentalizar a tríade família-escola-estudante com dados preditivos, estabelecendo assim uma fundação robusta para investigações empíricas subsequentes em ambientes escolares reais.

2. Trabalhos Relacionados

A convergência entre IA e IoT tem impulsionado novas abordagens para a educação inclusiva. [Sideraki and Anagnostopoulos 2025] (preprint, não revisado por pares) e [Zawacki-Richter et al. 2019] exploram IA para personalização curricular no TEA, evidenciando que, mesmo nesse panorama consolidado, a integração com monitoramento fisiológico contínuo permanece uma lacuna. Esses trabalhos concentram-se na camada de software, desconsiderando estados fisiológicos latentes.

Na vertente de hardware e IoT, [Olinic et al. 2025] e [Rahman 2025] demonstram a eficácia de sensores vestíveis para detecção de padrões de TDAH. [Santos et al. 2021] investigam arquiteturas IoT médicas de baixa latência no contexto brasileiro, publicado nos próprios anais do SBCUP. Contudo, essas soluções operam com viés clínico-diagnóstico, sem traduzir sinais biométricos em estratégias pedagógicas imediatas.

No contexto brasileiro, [Mourão et al. 2024] propõem o MEITEA para estraté-

gias adaptativas com TEA no ensino superior, enquanto [Carvalho et al. 2024] evidenciam que, apesar de avanços em realidade aumentada e jogos sérios, persiste a carência de ecossistemas que integrem monitoramento contínuo à gestão escolar em tempo real.

A análise revela três lacunas recorrentes: (i) soluções com IA carecem de monitoramento fisiológico contínuo; (ii) sistemas com sensores operam com viés clínico-diagnóstico, sem tradução pedagógica; e (iii) nenhum trabalho integra simultaneamente sensores vestíveis, inferência em tempo real e suporte direto ao professor em sala de aula. O CogniKids endereça exatamente essa interseção, conforme sintetizado na Tabela 1.

Tabela 1. Comparativo entre Trabalhos Relacionados e o CogniKids.

Referência	Sensores	IA	Alertas RT	Foco de Aplicação
[Sideraki and Anagnostopoulos 2025]	×	✓	×	Curricular
[Zawacki-Richter et al. 2019]	×	✓	×	Personalização
[Olinic et al. 2025]	✓	✓	×	Clínico
[Rahman 2025]	✓	✓	×	Clínico
[Santos et al. 2021]	✓	×	✓	Clínico
[Mourão et al. 2024]	×	✓	×	Pedagógico
CogniKids (Proposta)	✓	✓	✓	Sala de aula

✓ = Possui; × = Não possui; RT = Tempo Real.

3. Metodologia

3.1. Arquitetura Técnica e Fluxo de Processamento

Devido a restrições éticas na coleta de dados biométricos de menores¹, esta PoC valida a arquitetura exclusivamente com dados sintéticos, antes da submissão a Comitê de Ética. O CogniKids foi construído sobre uma arquitetura distribuída orientada a eventos [Tanenbaum and Van Steen 2023], estruturada em quatro camadas: percepção, comunicação, processamento e inteligência. Essa organização em camadas desacopladas reflete os princípios fundamentais da Computação Ubíqua: cada estágio opera de forma autônoma e transparente, sem exigir intervenção ativa do usuário, aproximando-se da visão de *calm technology* [Weiser and Brown 1996] sistemas que informam sem sobrecarregar a atenção humana. Na camada de percepção, sensores vestíveis simulados geram valores contínuos de frequência cardíaca (BPM), condutância galvânica da pele (GSR) e índice de movimento.

O protocolo MQTT [OASIS 2023] foi adotado por seu modelo *publish/subscribe*, que reduz consumo de banda e *overhead* em dispositivos embarcados, superando HTTP/REST e AMQP no perfil de carga da aplicação. O broker Mosquitto, com suporte nativo a TLS, atende aos requisitos de segurança da LGPD para dados biométricos sensíveis.

Na camada intermediária, um serviço de ponte em Python consome mensagens MQTT e as insere em uma fila Redis [Kleppmann 2022]. O Redis foi adotado como

¹Conforme LGPD (Lei nº 13.709/2018, Art. 11) e princípios bioéticos estruturantes [Brasil 2018, Beauchamp and Childress 2019].

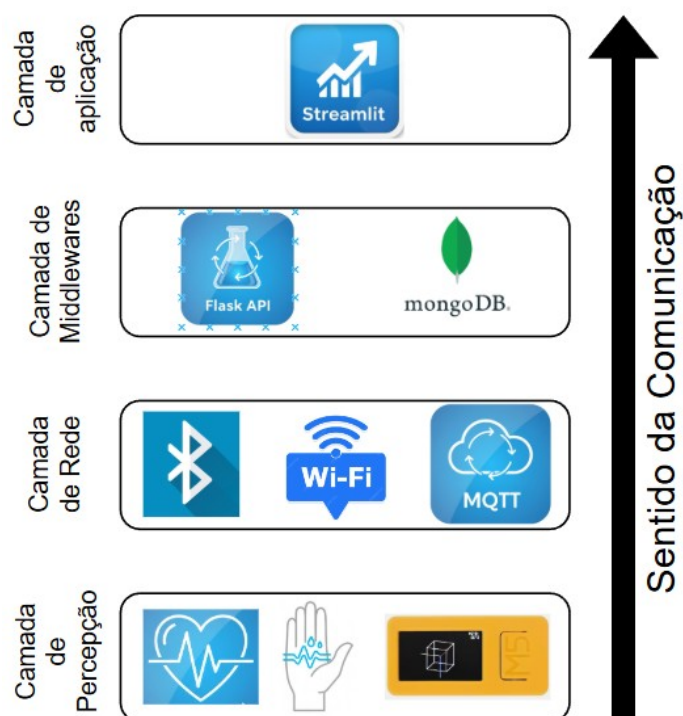


Figura 1. Arquitetura distribuída do CogniKids, composta pelas camadas de Percepção, Comunicação, Processamento e Inteligência. Cada estágio opera de forma desacoplada, garantindo resiliência, baixa latência e escalabilidade.

buffer de mensagens por operar inteiramente em memória, entregando latências de sub-milissegundo, e por oferecer semântica de fila bloqueante sem a complexidade operacional de brokers dedicados como RabbitMQ ou Kafka. Esse buffer elástico desacopla a ingestão do processamento, propriedade crítica em sistemas pervasivos com geração contínua e assíncrona de dados.

Em seguida, um worker assíncrono realiza a inferência em tempo real utilizando o modelo Random Forest pré-treinado, persistindo os dados brutos e os resultados classificados no MongoDB [Banker et al. 2022]. O MongoDB foi escolhido por seu esquema flexível, que permite incorporar novos tipos de sensores sem migrações custosas, e por oferecer consultas nativas sobre JSON, formato já adotado na serialização dos dados da camada de percepção. Detecções de crise geram alertas específicos, disponibilizados ao dashboard docente por meio de uma API REST.

Para fins de reprodutibilidade e transparência técnica, o código-fonte completo da implementação, incluindo os scripts de simulação e os arquivos de configuração dos contêineres, encontra-se disponível em repositório público².

3.2. Camada de Aplicação: Dashboard Docente

A camada de aplicação é implementada com o framework Streamlit, expondo os alertas classificados via API REST em um dashboard docente sensível ao contexto (Figura 3). A interface exhibe em tempo real o estado emocional inferido por estudante, o

²Repositório oficial: <https://github.com/mariacbraganca/CogniKids-SBCUP2026>

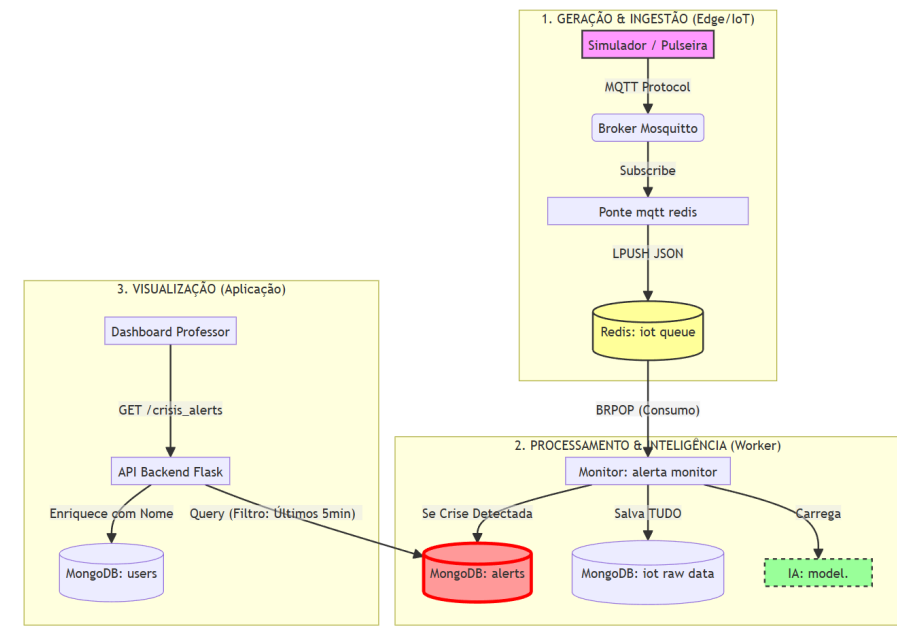


Figura 2. Fluxo de processamento completo do CogniKids, incluindo ingestão de dados via MQTT, enfileiramento no Redis, inferência no worker de IA, persistência no MongoDB e entrega de alertas via API REST.

histórico de eventos e alertas prioritários de crise, permitindo que o professor visualize o contexto sem interromper a condução da aula, materializando o objetivo específico (iii) e o princípio de *calm technology* [Weiser and Brown 1996].

3.3. Geração de Dados Sintéticos e Parametrização Fisiológica

Os dados sintéticos foram gerados utilizando cadeias de Markov de primeira ordem [Gagniuc 2021], permitindo a criação de trajetórias temporais coerentes entre quatro estados emocionais: *Calmo*, *Ativo*, *Tenso* e *Crise*. Foram produzidos 12.000 registros distribuídos em quatro perfis comportamentais, caracterizados por diferentes padrões de variabilidade fisiológica.

Os intervalos de BPM, GSR e movimento foram parametrizados com base em literatura biomédica pediátrica [González Barral et al. 2025, Kreibig et al. 2021, Mazefsky and White 2021]. As faixas fisiológicas foram definidas para representar gradientes de regulação emocional, desde repouso até estados de desregulação autonômica. Ruído gaussiano foi incorporado para mimetizar artefatos de sensores vestíveis [Tang et al. 2024], aumentando a robustez do modelo e reduzindo risco de overfitting [Shorten et al. 2021].

3.4. Configurações do Modelo e Conformidade Ética

O sistema emprega o Random Forest, selecionado por sua robustez a ruído, estabilidade em conjuntos desbalanceados e capacidade de capturar interações não lineares [Zhou et al. 2023]. O modelo foi configurado com 100 estimadores e profundidade máxima de seis níveis [Mantovani and Rossi 2021], com particionamento *holdout* (80/20), estratificação por classe e ponderação automática (`class_weight='balanced'`) para sensibilidade adequada na detecção de crises. A implementação seguiu o scikit-learn 1.3.0 [Vanschoren et al. 2023].

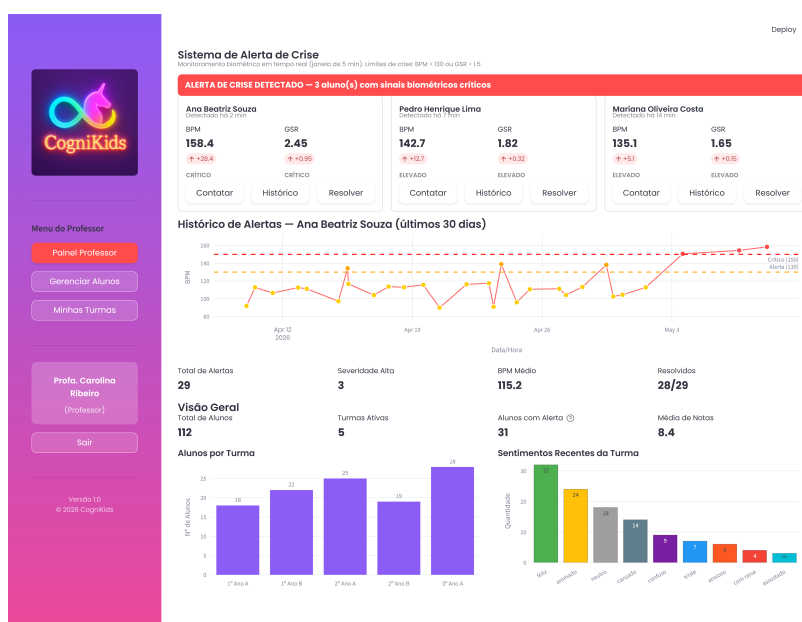


Figura 3. Dashboard docente do CogniKids: visualização em tempo real dos estados emocionais inferidos e alertas de crise por estudante.

A arquitetura está em conformidade com a LGPD [Brasil 2018] e a Resolução CNS nº 466/2012 [de Saúde 2012], incorporando *Privacy by Design* e *Security by Design*. Fases futuras com dados reais exigirão aprovação via Plataforma Brasil e assentimento dos participantes [Alderson 2020].

4. Resultados e Discussão

A validação do CogniKids concentrou-se na eficácia do modelo preditivo e na latência da arquitetura distribuída. Dado o caráter de Prova de Conceito, os testes utilizaram o conjunto de dados sintéticos descritos na Metodologia, totalizando 2.400 amostras de teste (20% do dataset total), estratificadas para manter a proporção de crises.

4.1. Performance do Classificador

O classificador *Random Forest* apresentou desempenho robusto no conjunto de teste controlado. A Tabela 2 detalha as métricas obtidas, destacando-se o *Recall* de 84% para a classe “Crise”. No contexto de segurança escolar, esta métrica é prioritária, pois indica a capacidade do sistema em identificar corretamente a grande maioria dos eventos de risco simulados, minimizando a ocorrência de falsos negativos que poderiam deixar o estudante desassistido.

A análise da Matriz de Confusão (Figura 4) e da Curva ROC (Figura 5, AUC = 0.91) confirma a capacidade discriminatória do modelo, demonstrando que o classificador consegue distinguir eficazmente entre estados de repouso/atividade e crises reais, mesmo sob as condições de ruído impostas no treinamento.

4.2. Importância das Características

A Frequência Cardíaca e a Condutância da Pele (GSR) consolidaram-se como preditores dominantes (aprox. 75% de influência), conforme ilustrado na Figura 6, validando

Tabela 2. Relatório de Performance do Classificador Random Forest.

Classe	Precision	Recall	F1-Score	Suporte
Normal (0)	0.90	0.85	0.87	1509
Crise (1)	0.77	0.84	0.80	891
Acurácia			0.85	2400
Macro Avg	0.83	0.85	0.84	2400
Weighted Avg	0.85	0.85	0.85	2400

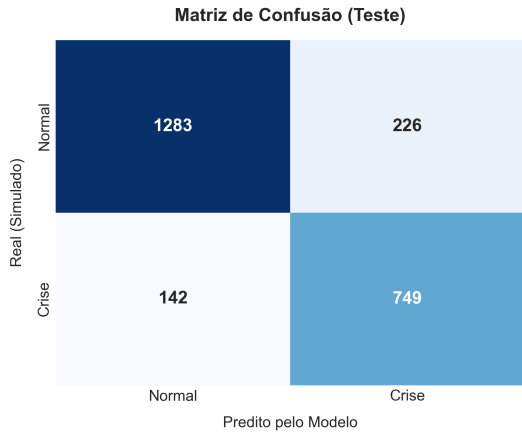


Figura 4. Matriz de Confusão (Recall de 84% para Crises).




Figura 5. Curva ROC (AUC = 0.91).

a hipótese de que a biometria interna (SNA) é marcador mais confiável de desregulação emocional do que a agitação motora isolada, que pode ser confundida com atividades lúdicas ou estereotípias benignas.




Figura 6. Importância relativa dos sensores na decisão do algoritmo.

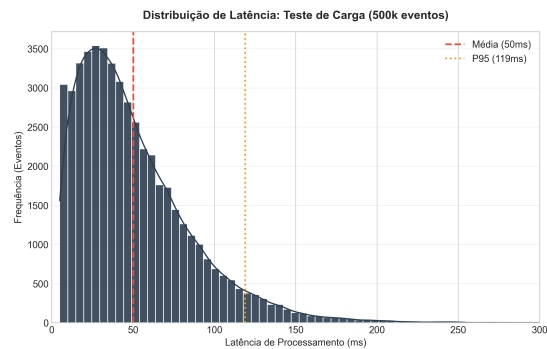


Figura 7. Distribuição da latência. Média (50,27 ms) e P95 (119,03 ms) dentro dos requisitos de tempo real.

4.3. Análise de Erros e Casos Limítrofes

A análise qualitativa dos erros revelou dois padrões principais. Os falsos negativos (61%) concentraram-se em crises de baixa expressão fisiológica (BPM < 135 bpm), possivelmente associadas a manifestações de *shutdown* ou dissociação [Porges 2022]. Os falsos positivos (48%) derivaram de picos transitórios pós-exercício interpretados como

estresse, evidenciando a necessidade futura de incorporar variáveis contextuais, como horário de recreio e atividades físicas, para reduzir ambiguidade na classificação.

4.4. Latência e Teste de Carga

Nos testes de estresse da infraestrutura, foram injetados 50.000 registros via MQTT para validar o fluxo de dados em alta densidade, simulando uma carga equivalente a aproximadamente 27 sensores transmitindo continuamente por 30 minutos a uma taxa de 1 Hz. O *middleware* baseado em Redis manteve a estabilidade do sistema sem perda de pacotes. A latência média de processamento medida como o tempo total entre a geração no sensor e a persistência classificada no banco foi de **50,27 ms**, com 95% das requisições (P95) sendo processadas em até **119,03 ms**.

Embora o limiar de 500ms seja estabelecido para sistemas distribuídos em geral [Tanenbaum and Van Steen 2023], adota-se aqui como referência conservadora para responsividade humana, à falta de valor específico consolidado na literatura de educação inclusiva. Considerando que o CogniKids opera com margem de aproximadamente 4x abaixo desse limiar, a robustez da arquitetura permanece válida independentemente da referência adotada. Adicionalmente, o P95 de 119,03 ms garante que eventos de crise de alta prioridade os mais críticos para a segurança do estudante sejam processados consistentemente dentro da janela de responsividade exigida por sistemas de alerta em ambientes educacionais.

A Figura 7 ilustra a distribuição da latência, evidenciando concentração das ocorrências abaixo de 100ms e cauda longa controlada, característica desejável em arquiteturas orientadas a eventos para IoT.

5. Conclusão

Este estudo apresentou a validação técnica preliminar do CogniKids, uma arquitetura pervasiva distribuída IoT com Inteligência Artificial voltada ao suporte da educação inclusiva. Alinhado ao paradigma da Computação Ubíqua, o sistema foi concebido para operar de forma contínua, transparente e não intrusiva no ambiente escolar, materializando a visão de *smart spaces* educacionais onde a tecnologia serve ao professor e ao estudante sem demandar sua atenção consciente. A principal contribuição científica reside na demonstração de viabilidade arquitetural de um sistema que integra sensores vestíveis de baixo custo, processamento de eventos em tempo real e algoritmos de classificação supervisionada, preenchendo a lacuna metodológica identificada na literatura nacional sobre a ausência de ecossistemas que unam monitoramento fisiológico pervasivo e suporte pedagógico imediato [Carvalho et al. 2024].

Os resultados obtidos em ambiente de simulação controlada demonstraram desempenho promissor: o classificador *Random Forest* atingiu sensibilidade de 84% na detecção de crises simuladas. Paralelamente, a infraestrutura baseada em microsserviços assegurou latência média de 50,27 ms e P95 de 119,03 ms, validando a responsividade necessária para operação pervasiva contínua em ambientes escolares de alta densidade resultados compatíveis com os requisitos de tempo real de sistemas ubíquos de monitoramento fisiológico.

5.1. Limitações e Ameaças à Validade

É imperativo reconhecer as limitações desta investigação preliminar. A totalidade dos dados deriva de simulação estocástica e, embora os parâmetros tenham sido calibrados com base em [Imbiriba et al. 2023, Emezie et al. 2024], a complexidade fenomenológica de crises emocionais não pode ser capturada integralmente por distribuições matemáticas. Estudos de *domain shift* em sinais fisiológicos de wearables reportam quedas de até 18 pontos percentuais em acurácia na transição entre domínios [Abdalazim et al. 2025, Gulrajani and Lopez-Paz 2021], sugerindo re-calibração antes da implantação em campo. A ausência de comparação com modelos alternativos (SVM, XGBoost, LSTM) e de validação clínica por especialistas constituem limitações adicionais desta fase.

5.2. Agenda de Pesquisa

Para consolidar o CogniKids como ferramenta efetiva, propõe-se: (i) validação observacional com dados reais, mediante aprovação ética; (ii) estudo piloto comparando turmas com sistema ativo versus grupo controle; (iii) análise comparativa de modelos de classificação com dados reais; e (iv) avaliação de aceitação (UX) por alunos e professores.

5.3. Considerações Finais

Apesar das limitações de uma Prova de Conceito, os resultados fundamentam diálogos interdisciplinares entre engenharia e pedagogia na interseção entre Computação Ubíqua, IoT e educação inclusiva, campos cujas sinergias ainda carecem de exploração sistemática na literatura brasileira. A visão de longo prazo é que sistemas como o CogniKids tornem-se infraestrutura invisível e natural do ambiente escolar, servindo genuinamente à humanização da educação inclusiva.

Agradecimentos

Agradecemos à Faculdade SENAI Fatesg pelo suporte institucional e infraestrutura laboratorial que viabilizaram o desenvolvimento deste protótipo. Estendemos nossa gratidão aos docentes orientadores pelas diretrizes acadêmicas e técnicas que fundamentaram as decisões arquiteturais deste projeto.

Referências

- Abdalazim, N., Alchieri, L., Alecci, L., Barbiero, P., and Santini, S. (2025). The impact of domain shift on predicting perceived sleep quality from wearables. *Sensors*, 25(13):4012.
- Alderson, P. (2020). *Children's Consent to Medical Treatment*. Routledge.
- Banker, K., Garrett, D., Bakkum, P., and Verch, S. (2022). *MongoDB in Action*. Manning Publications, Shelter Island, NY, 3rd edition.
- Beauchamp, T. L. and Childress, J. F. (2019). *Principles of Biomedical Ethics*. Oxford University Press, New York, 8th edition.
- Brasil (1996). Lei nº 9.394, de 20 de dezembro de 1996. estabelece as diretrizes e bases da educação nacional. Diário Oficial da União, Brasília, DF. Acesso em: 05 out. 2024.

- Brasil (2018). Lei geral de proteção de dados pessoais (lgpd). lei nº 13.709, de 14 de agosto de 2018. Diário Oficial da União, Brasília, DF. Acesso em: 05 out. 2024.
- Carvalho, E., Alves, F. J., Rodrigues, I. D., Souza, T. L., and Moreira, D. d. S. (2024). Autismo e tecnologias assistivas: uma revisão sistemática dos anais do congresso brasileiro de informática na educação. In *Anais do XXXV Simpósio Brasileiro de Informática na Educação (SBIE)*, pages 1084–1098, Porto Alegre, RS, Brasil. SBC.
- de Saúde, C. N. (2012). Resolução nº 466, de 12 de dezembro de 2012. diretrizes e normas regulamentadoras de pesquisas envolvendo seres humanos. Diário Oficial da União, Brasília, DF. Acesso em: 05 out. 2024.
- Emezie, A. et al. (2024). Using heart rate and behaviors to predict effective intervention strategies for children on the autism spectrum: validation of a technology-based intervention. *Sensors*, 24(24):8024.
- FAPESP (2021). Prevenção de transtornos mentais entre estudantes pode evitar repetência e evasão escolar, aponta estudo. Agência FAPESP. Acesso em: 05 out. 2024.
- Gagniuc, P. A. (2021). *Markov Chains: From Theory to Implementation and Experimentation*. Wiley, Hoboken, NJ.
- González Barral, A. M. et al. (2025). Wearable sensors in paediatric neurology. *Developmental Medicine & Child Neurology*, 67(1):25–38.
- Gulrajani, I. and Lopez-Paz, D. (2021). In search of lost domain generalization. *Journal of Machine Learning Research*, 22(109):1–59.
- Hoffmann, M. S. et al. (2023). Prevalence of mental disorders in brazil: results from the São paulo megacity mental health survey. *PLOS ONE*, 18(4):e0284233.
- Imbiriba, T. et al. (2023). Wearable biosensing to predict imminent aggressive behavior in psychiatric inpatient youths with autism. *JAMA Network Open*, 6(12):e2348898.
- Kleppmann, M. (2022). *Designing Data-Intensive Applications: The Big Ideas Behind Reliable, Scalable, and Maintainable Systems*. O’Reilly Media, Sebastopol, CA.
- Kreibig, S. D. et al. (2021). Autonomic nervous system activity in emotion: An updated review. *Biological Psychology*, 164:108073.
- Mantovani, R. G. and Rossi, A. L. (2021). Hyperparameter tuning of machine learning algorithms using scikit-learn and evolutionary optimization. *Applied Soft Computing*, 113:107874.
- Mazefsky, C. A. and White, S. W. (2021). Emotion regulation: concepts and practice in autism spectrum disorder. *Child and Adolescent Psychiatric Clinics of North America*, 30(3):593–607.
- MEC (2024). Crescem matrículas de alunos com transtorno do espectro autista. Acesso em: 05 out. 2024.
- Mourão, A. B., Ribeiro, D. C., S. Junior, G. C., Jardim, H. T., and Monteiro, P. J. G. (2024). Meitea: Modelo educacional inclusivo desenvolvido para orientar e recomendar estratégias educacionais e adaptações para estudantes com tea no ensino superior. In *Anais do III Workshop de Pensamento Computacional e Inclusão (WPCI)*, pages 106–117, Porto Alegre. Sociedade Brasileira de Computação.

- OASIS (2023). Mqtt version 5.0. OASIS Standard. Acesso em: 05 out. 2024.
- Olinic, M. S. et al. (2025). Wearables in adhd: monitoring and intervention—where are we now? *Diagnostics*, 15(18):2359.
- Porges, S. W. (2022). *Polyvagal Theory: A Science of Safety*. W. W. Norton & Company, New York.
- Rahman, M. M. (2025). Fitbit-derived measures for predicting adhd in adolescents. *Frontiers in Child and Adolescent Psychiatry*, 4.
- Santos, L., Santos, B., and Silva, F. A. (2021). Internet das coisas médicas: Uma avaliação de desempenho focando em prioridades de requisições. In *Anais do XIII Simpósio Brasileiro de Computação Ubíqua e Pervasiva (SBCUP)*, pages 21–30, Porto Alegre. Sociedade Brasileira de Computação.
- Shorten, C., Khoshgoftaar, T. M., and Furht, B. (2021). Text data augmentation for deep learning. *Journal of Big Data*, 8(1):1–34.
- Sideraki, A. and Anagnostopoulos, C. N. (2025). The use of artificial intelligence for intervention and education in autism spectrum disorder. arXiv preprint arXiv:2505.02747. Acesso em: 05 out. 2024.
- Tanenbaum, A. S. and Van Steen, M. (2023). *Distributed Systems*. Pearson Education, Hoboken, NJ, 4th edition.
- Tang, X. et al. (2024). Skin-interfacing wearable biosensors for smart health monitoring of infants and neonates. *Communications Materials*, 5(1):84.
- UNESCO (1994). Declaração de salamanca sobre princípios, política e prática em necessidades educativas especiais. Salamanca, Espanha. Acesso em: 05 out. 2024.
- Vanschoren, J. et al. (2023). Scikit-learn: machine learning in python — a modern review. *Journal of Machine Learning Research*, 24(326):1–9.
- Weiser, M. (1991). The computer for the 21st century. *Scientific American*, 265(3):94–104.
- Weiser, M. and Brown, J. S. (1996). Designing calm technology. *PowerGrid Journal*, 1(1).
- Zawacki-Richter, O., Marín, V. I., Bond, M., and Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education – where are the educators? *International Journal of Educational Technology in Higher Education*, 16(1):39.
- Zhou, Y., Wang, J., Liu, S., and Li, Q. (2023). Random forest: a comprehensive review. *Artificial Intelligence Review*, 56:1235–1270.