

Predicting Asthma Exacerbations in Digital Health Ecosystems Using Machine Learning Frameworks

Herbert Jung Sin · Martony Demes da Silva

Curso Superior de Tecnologia de Gestão de Dados — CEAD — Universidade Federal do Piauí (UFPI) — Teresina, PI, Brasil

afilaxy · triagem de risco de asma

RESUMO

A triagem do risco de exacerbações asmáticas agudas é crítica para ecossistemas de saúde digital. Este trabalho avalia um modelo de triagem inteligente para o app **Afilaxy**, classificando perfis de risco com base nos critérios clínicos da **GINA**. Quatro algoritmos de aprendizado de máquina foram comparados sobre um *dataset proxy* de perfis asmáticos; o **XGBoost** obteve AUC de **91,3%** e Sensibilidade de **89,2%** no limiar de decisão otimizado. A taxa remanescente de **10,8%** de falsos negativos exige cautela na interpretação clínica — este é um estudo de prova de conceito, que fundamenta hipóteses para futura implantação em dispositivos de borda, e não substitui o acompanhamento médico.

O Problema

- A asma afeta mais de **260 milhões** de pessoas no mundo e causa **450 mil mortes evitáveis** por ano (GINA, 2024). No Brasil, é uma das principais causas de internação pelo SUS.
- Entre consultas existe um **"vazio assistencial"**: sinais pré- crise — poluição, clima, sintomas leves — passam despercebidos pelo monitoramento convencional até a exacerbação aguda.
- O app **Afilaxy** monitora sintomas e ambiente, mas usa apenas um motor heurístico de pesos fixos — incapaz de capturar interações não lineares entre variáveis.

260M

PESSOAS COM ASMA
no mundo (GINA, 2024)

450 mil

MORTES EVITÁVEIS/ANO
GINA, 2024

OBJETIVO

Avaliar se algoritmos de Machine Learning podem substituir essa heurística por uma triagem de risco mais precisa, priorizando **Sensibilidade (Recall)** por segurança clínica.

Dados

- Asthma Disease Dataset (Kaggle, CC BY 4.0) — **2.392** perfis sintéticos, **15** variáveis preditoras finais.
- Rótulo `high_risk` definido pelo critério GINA (soma de 5 sintomas ativos ≥ 3) — não pelo diagnóstico original, que responde a outra pergunta clínica.
- Distribuição naturalmente balanceada entre as classes do rótulo — sem necessidade de SMOTE:
- 4 variáveis sintéticas emulam dados nativos do Afilaxy (`riskScore`, `emergencyCount`, `hadCrisisToday`, `hasRescueInhaler`), geradas com seed fixo — reprodutibilidade total.

58,1%

Alto risco (rótulo GINA)


41,9%

Baixo risco

CONTRIBUIÇÃO CIENTÍFICA

Formulação de uma abordagem de triagem integrada ao ecossistema Afilaxy, combinando a adaptação das diretrizes clínicas GINA para rotulamento automático e um estudo comparativo de modelos com foco em segurança clínica — estabelecendo os requisitos teóricos para futura implantação em borda.

Método



Regressão Logística, Random Forest, Gradient Boosting e XGBoost foram comparados sob validação cruzada estratificada, com teste *holdout* independente de 20% da base.


Resultados

		91,3%	89,2%
		AUC (TESTE) XGBoost	RECALL (SENSIBILIDADE) limiar calibrado 0,466

MODELO	CV AUC	AUC TESTE	RECALL	F1
Regressão Logística	0,942	0,933	0,867	0,870
Random Forest	0,862	0,881	0,899	0,843
Gradient Boosting	0,921	0,910	0,860	0,854
XGBoost	0,922	0,913	0,867	0,859

0,50 → 86,7% LIMIAR PADRÃO · RECALL	0,466 → 89,2% LIMIAR CALIBRADO (F1-ÓTIMO) · RECALL
--	---


Precisão, Recall e F1-Score em função do limiar de decisão (XGBoost, dados de teste)



NOTA METODOLÓGICA

O limiar foi calibrado para maximizar o F1-Score, elevando o Recall sem degradar a precisão de forma proporcional. Sem teste de hipótese formal, a superioridade estatística do XGBoost sobre a Regressão Logística não pode ser afirmada com rigor — o XGBoost foi adotado pela regularização L1/L2 e compatibilidade com inferência *on-device*.

Importância de Atributos



As duas variáveis mais relevantes são nativas do Afilaxy — validando o valor preditivo dos dados já coletados pelo app.

Limitações

- Base **sintética e transversal** — resultados ainda não refletem dados longitudinais reais do app.
- `riskScore` como feature cria sobreposição indireta com o rótulo; remoção prevista em estudos de ablação.
- 10,8%** de falsos negativos remanescentes — a ferramenta complementa, não substitui, o acompanhamento médico.
- Hipótese de inferência *on-device* ainda não testada empiricamente (bateria, latência, RAM).
- O Afilaxy já possui arquitetura (*scaffolds*) para 7 variáveis nativas adicionais — frequência cardíaca, SpO2 e padrões de sono, via HealthConnect/HealthKit — atualmente inativas na v2.3.1 e ausentes do *dataset proxy*.

Conclusão & Próximos Passos

- Prova de conceito: modelos baseados em árvores superam a heurística fixa na captura de padrões não lineares entre clima e sintomas.
- Próximos passos: retreinamento com dados longitudinais nativos, testes formais de significância estatística, *benchmark* de inferência *on-device* e janelas preditivas temporais.

Trabalhos Relacionados

- Bousquet et al. (2017)** — MASK-asthma: app de autorrelato diário eleva adesão, mas fica restrito a heurísticas clínicas estáticas.
- Merchant et al. (2016)** — sensores acoplados a inaladores + AQI mapeiam gatilhos urbanos de exacerbação.
- Alotaibi et al. (2020)** — revisão sistemática: comitês de árvores superam modelos lineares em dados climáticos heterogêneos.
- Patel et al. (2021)** — a maior barreira à IA em saúde móvel é a sensibilidade sob baixa complexidade, não a acurácia isolada.

