




Modelagem Computacional no
Sertão Mineiro



PPGMCS
Programa de Pós-Graduação em
Modelagem Computacional e Sistemas

MODELAGEM PREDITIVA E EXPLICABILIDADE NA IDENTIFICAÇÃO DE PREDITORES DA SAÚDE MENTAL DE MÃES DE CRIANÇAS COM TEA

Milena Beatriz Batista da Mota¹ - mbbm@aluno.ifnmg.edu.br

Marcelo Perim Baldo² - marcelo.baldo@unimontes.br

Marcos Flávio Silveira Vasconcelos Dangelo² - marcos.dangelo@unimontes.br

Cleiane Gonçalves Oliveira¹ - cleiane.oliveira@ifnmg.edu.br

¹Instituto Federal do Norte de Minas Gerais - Campus Januária, IFNMG - Januária, MG, Brasil

²Universidade Estadual de Montes Claros, UNIMONTES - Montes Claros, MG, Brasil

Abstract. Este estudo investigou os determinantes associados à co-ocorrência sintomática de ansiedade e depressão em mães de crianças com Transtorno do Espectro Autista (TEA), utilizando dados secundários do projeto SOLACE ($n = 2.008$). Visando superar a opacidade de algoritmos de Machine Learning em dados de saúde pública, propôs-se um pipeline preditivo e estatisticamente validado via Validação Cruzada Aninhada (10-fold externo e 5-fold interno com GridSearchCV) comparando seis modelos: Regressão Logística, Random Forest, XGBoost, SVM, MLP e Árvore de Decisão. Os resultados demonstraram equivalência na capacidade discriminatória global entre os cinco principais algoritmos ($AUC \approx 0,82$ a $0,83$, $p \geq 0,05$). A Regressão Logística foi selecionada como o modelo definitivo por apresentar maior sensibilidade (71,25%) na identificação do grupo de elevada vulnerabilidade clínica, superando modelos complexos não-lineares. A análise de explicabilidade global via SHAP revelou a dominância absoluta de construtos psicológicos internos — especificamente a baixa autoestima, autocompaixão e qualidade de vida — como os principais indutores da vulnerabilidade psíquica, reduzindo a importância preditiva de fatores socioeconômicos estruturais (como renda, desemprego e suporte social) quando em competição aditiva. Conclui-se que intervenções voltadas ao fortalecimento do suporte emocional interno são prioritárias para a mitigação do risco de adoecimento psíquico materno.

Keywords: Transtorno do Espectro Autista, Saúde Mental Materna, Machine Learning, Inteligência Artificial Explicável (XAI), SHAP.

1. INTRODUÇÃO

O mapeamento de indicadores de saúde mental e qualidade de vida em grupos vulneráveis frequentemente envolve a análise de interações entre fatores psicossociais e determinantes

sociodemográficos. No cenário do Transtorno do Espectro Autista (TEA), a literatura aponta que a figura materna, culturalmente posicionada como cuidadora principal, enfrenta intensas demandas de acompanhamento multidisciplinar. Esse cuidado contínuo associa-se a elevados níveis de estresse, sobrecarga emocional e propensão ao desenvolvimento de quadros depressivos (Sauer *et al.*, 2021; Reis, 2023; Sampaio *et al.*, 2026). Com o objetivo de compreender essas dinâmicas, o projeto SOLACE coletou dados de mais de 1.900 mães de crianças com TEA no contexto brasileiro, mapeando variáveis relacionadas às mães e aos filhos. Contudo, na investigação dos determinantes de maior impacto, os métodos estatísticos tradicionais são limitados pela alta dimensionalidade dos dados.

Nesse cenário, modelos preditivos de *Machine Learning* (ML) se apresentam como uma abordagem viável para processar grandes volumes de dados e extrair padrões complexos. No entanto, a aplicação de algoritmos de alta capacidade preditiva na área da saúde enfrenta o desafio da opacidade dos modelos conhecidos como "caixa-preta", cuja baixa interpretabilidade compromete a confiabilidade dos resultados obtidos. Para resolver essa limitação, a área de Inteligência Artificial Explicável (*Explainable Artificial Intelligence* - XAI) fornece métodos *post-hoc* capazes de auditar as previsões e atribuir métricas de importância local e global aos atributos de entrada (Rane *et al.*, 2023).

Diante disso, este trabalho busca responder ao seguinte problema de pesquisa: de que maneira técnicas de Inteligência Artificial Explicável, aplicadas a modelos de Machine Learning validados estatisticamente, podem auxiliar na identificação e ordenação dos determinantes sociodemográficos que mais impactam a saúde mental de mães de crianças com TEA no ecossistema de dados do projeto SOLACE?

As principais contribuições deste estudo consistem em: (i) propor um pipeline preditivo e estatisticamente validado para mapear a co-ocorrência de ansiedade e depressão em mães de crianças com TEA; e (ii) extrair explicações globais via Shapley Values (SHAP) para identificar quais fatores sociodemográficos atuam como preditores críticos.

2. METODOLOGIA

O estudo utilizou dados secundários do projeto SOLACE (Cruz *et al.*, 2024), um estudo transversal e analítico nacional realizado via formulário *online* com 2.008 participantes validadas. O objetivo original foi investigar preditores de qualidade de vida e saúde mental em mães de crianças com TEA, cujos diagnósticos foram autorrelatados pelas participantes sem verificação clínica independente (Maia *et al.*, 2024). O conjunto de atributos preditores (*features*) foi estruturado em dois blocos principais: (i) dados maternos (idade, raça/cor, estado civil, escolaridade, renda, situação funcional, hábito de fumar, consumo de álcool, número total de filhos e de filhos com TEA, autoestima, autocompaixão e suporte social); e (ii) características dos filhos (idade, sexo, raça/cor, idade ao diagnóstico, tempo de diagnóstico, uso de medicação contínua e linguagem).

Para modelar a vulnerabilidade da saúde mental materna e garantir a integridade dos modelos sem risco de vazamento de dados (*data leakage*), as variáveis contínuas e categorizações de estresse, ansiedade e depressão foram removidas do conjunto de variáveis preditoras. Em seu lugar, foi estabelecida a variável-alvo binária "*Saude Mental Materna*", focada na estimativa da co-ocorrência sintomática.: a Classe 1 define o grupo de vulnerabilidade clínica elevada, representando a presença concomitante de ansiedade e depressão, enquanto a Classe 0 sinaliza a 'Sem Co-ocorrência' dessas condições. Dessa forma, o problema foi

modelado para a predição e estratificação do risco de adoecimento psíquico, e não para o diagnóstico clínico confirmatório.

O *pipeline* preditivo e de explicabilidade foi conduzido em quatro etapas sequenciais. Primeiramente seis abordagens de aprendizado de máquina com distintas complexidades matemáticas foram comparadas: Regressão Logística, Árvore de Decisão, *Random Forest*, *Support Vector Machine* (SVM), *Multi-Layer Perceptron* (MLP) e *XGBoost*. Em seguida, empregou-se uma Validação Cruzada Aninhada (*Nested Cross-Validation*). O *loop* externo de 10 *folds* avaliou a capacidade de generalização do sistema, enquanto o *loop* interno de 5 *folds* realizou o ajuste fino de hiperparâmetros via *GridSearchCV*, otimizando a métrica F_1 -Macro.

Adiante, as métricas de Acurácia, Precisão, *Recall* (Sensibilidade), *F1-Score* e AUC-ROC geradas no ciclo externo foram agregadas por média aritmética. A equivalência estatística entre os modelos foi aferida por meio do Teste T Pareado (p -valor < 0,05). O critério de seleção do modelo definitivo priorizou a maximização do *Recall* na Classe 1, visando reduzir falsos negativos no rastreamento de mães em situação de alto risco psíquico. E por fim, modelo selecionado foi retreinado com 100% do conjunto de dados e submetido à análise de explicabilidade via SHAP (*SHapley Additive exPlanations*). Essa etapa permitiu calcular e ranquear o valor de importância individual de cada preditor sociodemográfico e psicológico na estimativa final de risco.

3. RESULTADOS E DISCUSSÃO

3.1 Avaliação de Desempenho e Seleção do Modelo

A Tabela 1 mostra os resultados médios de desempenho obtidos pelos classificadores após o processo de validação cruzada aninhada para ambas as classes preditivas.

Table 1: Desempenho médio dos modelos por classe preditiva após validação cruzada aninhada.

Modelo	Classe	Acurácia	Precisão	Recall	<i>F1-Score</i>	AUC-ROC
MLP	Classe 0	0,7605	0,7951	0,8450	0,8190	0,8221
	Classe 1		0,6890	0,6085	0,6452	
Random Forest	Classe 0	0,7531	0,8112	0,8066	0,8075	0,8272
	Classe 1		0,6559	0,6568	0,6525	
Regressão Logística	Classe 0	0,7448	0,8274	0,7626	0,7921	0,8268
	Classe 1		0,6324	0,7125	0,6668	
SVM	Classe 0	0,7463	0,8015	0,8083	0,8022	0,8247
	Classe 1		0,6602	0,6345	0,6403	
XGBoost	Classe 0	0,7563	0,7985	0,8326	0,8141	0,8270
	Classe 1		0,6777	0,6185	0,6432	
Árvore de Decisão	Classe 0	0,7348	0,8042	0,7780	0,7885	0,7916
	Classe 1		0,6330	0,6568	0,6395	

Para a identificação de instâncias da Classe 0 (mães sem co-ocorrência de sintomas), o modelo *Multi-Layer Perceptron* (MLP) obteve melhor comportamento, com maior Acurácia Global (76,05%), *Recall* (84,50%) e índice *F1-Score* (81,90%). Contudo, em problemas aplicados à saúde pública, a priorização diagnóstica é encontrar um modelo que tenha melhor sensibilidade em identificar a classe de risco (Classe 1). Nesse cenário, a Regressão Logística

se destacou alcançando o maior *Recall* (71, 25%) e o maior *F1-Score* (66, 68%) para o grupo de alta vulnerabilidade.

A capacidade discriminatória global (AUC-ROC, Figura 1) demonstrou equivalência entre Regressão Logística, Random Forest, XGBoost, SVM e MLP (AUC = 0,82 a 0,83), sem diferença estatisticamente significativa pelo Teste T pareado ($p \geq 0,05$). Apenas a Árvore de Decisão isolou-se com desempenho inferior (AUC = 0,79 ± 0,04).




Figure 1: Curva AUC-ROC dos modelos preditivos avaliados para a Saúde Mental Materna.

A validação por meio da matriz de testes estatísticos (Teste T pareado) confirmou essa equivalência. Não houve diferença estatisticamente significativa (p -valor $\geq 0,05$) entre os desempenhos desses cinco modelos de topo. A Árvore de Decisão isolou-se com o pior desempenho discriminatório (AUC = 0,79 ± 0,04).

O fato de um modelo linear simples como a Regressão Logística apresentar desempenho semelhante a arquiteturas de maior complexidade e não-lineares (como *XGBoost* e redes neurais MLP) valida a hipótese de que, no ecossistema de dados do projeto SOLACE, os determinantes sociodemográficos e clínicos possuem caráter aditivo e linear sobre os indicadores de saúde mental das mães.

Sob a premissa de que, entre hipóteses com desempenho equivalente, deve-se privilegiar a mais simples, os resultados sugerem que uma estrutura linear é suficiente para descrever o fenômeno investigado. Como a Regressão Logística conseguiu rastrear corretamente 71,25% das mães em situação de severo desgaste emocional — superando de forma expressiva algoritmos complexos como o *XGBoost* (61,85%), aliada ao fato de ser uma estrutura intrinsecamente transparente e auditável, ela foi selecionada como o modelo definitivo para prosseguir para a etapa de explicabilidade via SHAP.

3.2 Análise de Explicabilidade via SHAP

A explicabilidade global foi extraída via SHAP, utilizando KernelExplainer com amostragem sintética via KNN (50 instâncias), reduzindo a complexidade computacional sem

comprometer a representatividade do espaço de atributos.

A Figura 2 exibe o gráfico de densidade (*Beeswarm plot*) da Regressão Logística, modelo escolhido como ideal para o contexto do banco de dados. Na análise de todos os resultados do SHAP, todos os modelos convergiram para a mesma ordenação de impacto das principais variáveis preditoras.




Figure 2: Gráfico Beeswarm do SHAP para o modelo de Regressão Logística.

A análise do comportamento global revela que o indicador de Autoestima aparece como a *feature* de maior relevância para todos os modelos, seguida imediatamente por Autocompaixão e Qualidade de vida. O comportamento das cores no gráfico revela que baixos valores dessas três métricas psicológicas (pontos em azul) exercem um severo deslocamento positivo no SHAP *value* (eixo horizontal para a direita), atuando como os principais indutores da predição da Classe 1 (vulnerabilidade clínica para ansiedade e depressão concomitantes). Clinicamente, esse padrão indica que a escassez de recursos de enfrentamento interno e a baixa percepção de bem-estar individual são os gatilhos matemáticos primários para o colapso da saúde mental materna.

Observou-se que as variáveis nas posições 4 e 5, que mais impactam os modelos, variaram substancialmente entre as diferentes arquiteturas avaliadas. Esse comportamento computacional vai contra alguns achados epidemiológicos do projeto SOLACE. Enquanto a análise descritiva original identificou a renda menor que dois salários mínimos, o desemprego e baixos níveis de suporte social (SS) como fatores fortemente associados à co-ocorrência sintomática, o SHAP revelou que, no cenário preditivo global, essas variáveis socioeconômicas e estruturais não apresentaram um impacto importante.

O suporte social, por exemplo, despontou como uma característica de maior relevância global exclusivamente no modelo *Random Forest* (*SS_familia* e *SS_amigos* ocupando o bloco

intermediário). Nos demais modelos, variáveis como Severidade tercil e a presença de animais de estimação flutuaram nessas posições de destaque secundário. Essa divergência sugere que, quando determinantes socioeconômicos competem com construtos psicológicos de elevada contribuição aditiva, como autoestima e autocompaixão, sua importância preditiva tende a ser reduzida no modelo. Portanto, ainda que variáveis como renda, situação ocupacional e suporte social sejam reconhecidos como importantes determinantes, o modelo atribuiu maior importância preditiva aos recursos psicológicos internos na estimativa do risco de adoecimento psíquico das cuidadoras.

4. CONCLUSÕES

A avaliação de desempenho revelou um empate estatístico na área sob a curva ROC ($AUC \approx 0,83$) entre os cinco principais algoritmos. Por critério de melhor sensibilidade, adequado ao contexto de predição aplicada à saúde, a Regressão Logística foi eleita o modelo definitivo por sua capacidade superior em rastrear falsos negativos na classe de risco (*Recall* de 71,25% na co-ocorrência sintomática) e por sua transparência intrínseca.

A etapa de explicabilidade via SHAP resultou na contraposição da análise estatística tradicional. O comportamento global dos modelos demonstrou uma dominância preditiva absoluta de construtos psicológicos internos, especificamente a Autoestima e a Autocompaixão, cujos baixos níveis impactam a saúde mental. Além disso, a mudança na posição das variáveis socioeconômicas (renda, desemprego e suporte social) entre as diferentes arquiteturas evidenciou que a importância preditiva desses fatores estruturais diminui quando eles competem, no mesmo modelo, com fatores psicológicos.

Como trabalhos futuros, sob a perspectiva da engenharia de recursos, sugere-se a exploração e comparação de técnicas de seleção de atributos (*feature selection*), como algoritmos baseados em filtros ou invólucros (*wrapper methods*), aplicadas previamente à etapa de modelagem, visando reduzir a dimensionalidade do espaço de características, otimizar o tempo de computação dos *explainers* e isolar os componentes puramente dominantes para a predição da vulnerabilidade psíquica.

Acknowledgements

Os autores agradecem à FAPEMIG (grant n OET-00243-26).

REFERENCES

- Cruz, V. P. D. et al. (2024), “Socioeconomic status and the perceived social support in mothers of children with autism spectrum disorder: the SOLACE-Brasil study”, *International Journal of Developmental Disabilities*, p. 1–12.
- Maia, R. F. et al. (2024), “Quality of life among mothers of children with autism spectrum disorder in Brazil: influence of socioeconomic status”, *International Journal of Developmental Disabilities*, p. 1–11.
- Rane, N., Choudhary, S. and Rane, J. (2023), “Explainable Artificial Intelligence (XAI) in healthcare: Interpretable Models for Clinical Decision Support”, *Social Science Research Network*.
- Reis, D. A. dos (2023), “Qualidade de Vida e Saúde Mental de Mães de Crianças com TEA”, Dissertação (Mestrado), Universidade Presbiteriana Mackenzie, São Paulo.
- Sampaio, I. L. G. et al. (2026), “Conhecimento dos pais sobre o transtorno do Espectro Autista e o impacto do diagnóstico no contexto familiar”, *Research, Society and Development*, v. 15, n. 4.
- Sauer, A. K. et al. (2021), “Autism Spectrum Disorders: Etiology and Pathology”, in *Autism Spectrum Disorders*, A. M. Grubcker (ed.), Exon Publications, Brisbane, p. 1–15.