

Multilayer Perceptron-Based System for Behavioral Analysis and Educational Recommendation in Autism Spectrum Disorder

Ângela M. A. Souza

Bacharelado Interdisciplinar em Tecnologia da Informação
Universidade Federal Rural do Semi-Árido
Rio Grande do Norte, Brasil
angela.souza@alunos.ufersa.edu.br

Rosana C. B. Rego

Departamento de Engenharias e Tecnologia
Universidade Federal Rural do Semi-Árido
Rio Grande do Norte, Brasil
rosana.rego@ufersa.edu.br

Abstract—Autism Spectrum Disorder (ASD) requires early identification and effective educational intervention. This study presents a multilayer perceptron neural network to identify behavioral patterns associated with ASD from questionnaire responses. The model achieved 100% accuracy, precision, recall, and F1-score on the test set ($N_{\text{test}} = 211$). A rule-based interpretative layer translates model outputs into educational profiles and personalized pedagogical recommendations, enabling practical support for educators. The integration of machine learning with educational strategies demonstrates the potential of AI as a support tool for inclusive education and early intervention.

Index Terms—Autism spectrum disorder, inclusive education, multilayer perceptron, behavioral analysis, neural network.

I. INTRODUÇÃO

O Transtorno do Espectro Autista (TEA) é uma condição neurodesenvolvimental de base neurológica, cujas principais características incluem dificuldades na comunicação e interação social, bem como padrões restritos e repetitivos de comportamentos, interesses ou atividades. O termo “espectro” denota a heterogeneidade das manifestações clínicas do transtorno, indicando que os sintomas variam em intensidade, desde formas leves até graves, nas dimensões sociocomunicativa e comportamental, ao invés de representarem categorias diagnósticas isoladas. A identificação do TEA ocorre com frequência entre 12 e 24 meses de idade, podendo manifestar-se por meio de atrasos no desenvolvimento ou mesmo pela regressão de habilidades anteriormente adquiridas, evidenciando a necessidade de detecção e intervenção precoces [1]. A intervenção deve começar no ponto mais precoce possível, pois a detecção e intervenção precoces resultam em desfechos positivos para a criança, a família e a sociedade [2]. No entanto, barreiras no acesso a serviços de saúde afetam 29% das crianças com TEA, incluindo dificuldades para conseguir consultas com rapidez suficiente, longos tempos de espera no consultório e problemas para encontrar profissionais especializados [3].

Paralelamente, a inteligência artificial (IA) tem emergido como uma ferramenta promissora na área da saúde, especialmente no suporte ao diagnóstico de transtornos do neurodesenvolvimento [4]. Modelos de aprendizado de máquina, como

redes neurais artificiais, podem aprender padrões complexos a partir de dados comportamentais e auxiliar profissionais na triagem inicial [5].

Este artigo propõe um modelo baseado em rede neural Perceptron Multicamada (MLP) para classificar a probabilidade de traços de TEA em crianças pequenas a partir de características individuais e respostas de um questionário comportamental. Além disso, o modelo incorpora uma camada interpretável baseada em regras que, a partir das respostas individuais, gera um perfil comportamental e recomenda estratégias pedagógicas personalizadas, alinhando-se aos princípios da educação inclusiva.

II. TRABALHOS RELACIONADOS

Diversos estudos têm explorado o uso de inteligência artificial e aprendizado de máquina para triagem e diagnóstico do TEA. Thabtah [6] propôs um sistema de triagem para TEA baseado em aprendizado de máquina, adaptado aos critérios do DSM-5, demonstrando a viabilidade do uso de questionários comportamentais para identificação precoce. O autor desenvolveu diferentes conjuntos de dados para crianças, adolescentes e adultos, incluindo o *Autism Dataset for Toddlers* utilizado no presente trabalho.

Wall et al. [7] aplicaram algoritmos de aprendizado de máquina para reduzir o tempo de diagnóstico do TEA, alcançando alta acurácia na classificação a partir de um número reduzido de questões comportamentais. O estudo demonstrou que é possível manter a precisão diagnóstica com menos itens, facilitando a triagem em larga escala.

Anagnostopoulou et al. [4] realizaram uma revisão sobre aplicações de inteligência artificial na avaliação do autismo, destacando o potencial de redes neurais e algoritmos de classificação para auxiliar profissionais da saúde no processo diagnóstico. Os autores apontam que a IA pode reduzir a subjetividade inerente aos métodos tradicionais.

Francese e Yang [5] conduziram uma revisão sistemática da literatura sobre o uso de aprendizado de máquina e dispositivos vestíveis (*wearables*) no suporte à triagem e intervenção do TEA. Os resultados indicam um crescimento significativo de

pesquisas na área, embora a maioria ainda esteja em estágio experimental.

Diferentemente dos trabalhos anteriores, que focam exclusivamente na classificação binária, o presente estudo propõe uma camada interpretável adicional que traduz as predições do modelo em perfis comportamentais e recomendações pedagógicas personalizadas, ampliando a utilidade da ferramenta para educadores e profissionais da saúde.

III. METODOLOGIA

A. Base de Dados

Utilizou-se o *Autism Dataset for Toddlers*¹, com $N = 1054$ registros e $d = 19$ variáveis. O conjunto $\mathcal{D} = \{(\mathbf{x}_i, y_i)\}_{i=1}^N$ contém respostas binárias a 10 questões comportamentais ($A1, \dots, A10$) $\in \{0, 1\}^{10}$, além de variáveis demográficas, como idade em meses, sexo, etnia, icterícia neonatal, histórico familiar de TEA e o respondente. A variável alvo $y \in \{0, 1\}$ indica a ausência ou presença de traços de TEA.

Aplicou-se *LabelEncoder* para codificar variáveis categóricas em representações numéricas ordinais. A Tabela I apresenta a distribuição das classes após a codificação.

TABLE I
DISTRIBUIÇÃO DAS VARIÁVEIS CATEGÓRICAS APÓS CODIFICAÇÃO

Variável	Categoria	Contagem
Class/ASD Traits	Traços presentes (1)	728
	Traços ausentes (0)	326
Jaundice	Não (0)	766
	Sim (1)	288
Sex	Masculino (1)	735
	Feminino (0)	319
Family_mem_with_ASD	Não (0)	884
	Sim (1)	170

B. Análise Exploratória

A análise exploratória revelou padrões consistentes com a literatura. Em relação à etnia (Figura 1), observaram-se diferenças significativas na prevalência entre grupos étnicos. Quanto à icterícia neonatal (Figura 2), a maioria dos casos com traços de TEA ocorreu em crianças sem histórico de icterícia. A distribuição por sexo (Figura 3) mostrou prevalência significativamente maior no sexo masculino, consistente com a literatura especializada. Por fim, analisando o histórico familiar (Figura 4), das 1054 crianças, 884 não possuíam histórico familiar e 170 apresentavam histórico positivo, com predominância de traços de TEA em ambos os grupos, sendo este achado mais expressivo no grupo com histórico familiar.

¹<https://www.kaggle.com/datasets/vaishnavisirigiri/autism-dataset-for-toddlers>




Fig. 1. Distribuição dos traços de TEA por etnia.




Fig. 2. Distribuição dos traços de TEA por presença de icterícia neonatal.




Fig. 3. Distribuição dos traços de TEA por sexo.




Fig. 4. Distribuição dos traços de TEA por histórico familiar de TEA.

C. Definições para Modelagem

O conjunto foi dividido estratificadamente em $\mathcal{D}_{\text{train}}$ (80%, $N_{\text{train}} = 843$) e $\mathcal{D}_{\text{test}}$ (20%, $N_{\text{test}} = 211$). Para normalização, aplicou-se `StandardScaler` para padronização Z-score:

$$\mathbf{z} = \frac{\mathbf{x} - \boldsymbol{\mu}}{\boldsymbol{\sigma}} \quad (1)$$

Devido ao desbalanceamento observado ($N_1 = 728$, $N_0 = 326$), aplicaram-se pesos às classes durante o treinamento:

$$w_0 = \frac{N}{2N_0} = 1.686, \quad w_1 = \frac{N}{2N_1} = 0.711 \quad (2)$$

D. Arquitetura da Rede Neural

O modelo feedforward totalmente conectado possui a seguinte arquitetura:

$$\begin{array}{l} \mathbb{R}^{18} \xrightarrow{\text{Dense}(128)} \mathbb{R}^{128} \\ \xrightarrow{\text{Dropout}(0.3)} \\ \xrightarrow{\text{Dense}(64)} \mathbb{R}^{64} \\ \xrightarrow{\text{Dropout}(0.3)} \\ \xrightarrow{\text{Dense}(1)} \mathbb{R}^1 \end{array} \quad (3)$$

A primeira camada oculta contém 128 neurônios com ativação ReLU, onde $f(x) = \max(0, x)$. A segunda camada oculta possui 64 neurônios, também com ativação ReLU e regularização L2:

$$\mathcal{L}_{\text{reg}} = \mathcal{L}_{\text{BCE}} + \lambda \sum_i w_i^2, \quad \lambda = 0.01 \quad (4)$$

A camada de saída contém 1 neurônio com ativação sigmoide:

$$P(y = 1|\mathbf{x}) = \sigma(z) = \frac{1}{1 + e^{-z}} \quad (5)$$

O total de parâmetros treináveis do modelo é 10.753, conforme detalhado na Tabela II.

TABLE II
ARQUITETURA DA REDE NEURAL COM REGULARIZAÇÃO L2

Camada	Tipo	Parâmetros
1	Dense (128, ReLU)	2.432
2	Dropout (0.3)	0
3	Dense (64, ReLU) + L2(0.01)	8.256
4	Dropout (0.3)	0
5	Dense (1, Sigmoid)	65
Total de parâmetros		10.753

E. Treinamento

O treinamento utilizou entropia cruzada binária com pesos de classe como função de custo:

$$\mathcal{L} = -\frac{1}{N} \sum_{i=1}^N w_{y_i} [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)] \quad (6)$$

O otimizador Adam foi configurado com taxa de aprendizado $\alpha = 0.001$ e parâmetros $\beta_1 = 0.9$, $\beta_2 = 0.999$. Os hiperparâmetros incluíram épocas máximas de 40, batch size de 32 e validação com 20% de $\mathcal{D}_{\text{train}}$. Para regularização, implementou-se early stopping com paciência de 15 épocas, monitorando $\mathcal{L}_{\text{val}}$ e restaurando os melhores pesos ao final do treinamento. A Figura 5 mostra a convergência da função de perda durante o processo.




Fig. 5. Função de perda ao longo das épocas para os conjuntos de treino e validação.

F. Camada Interpretável e Recomendação de Estratégias

Implementou-se uma camada interpretável baseada em regras determinísticas. A função de mapeamento $\Phi: \{0, 1\}^{10} \rightarrow \mathcal{P}$ transforma as respostas ($A_1, \dots, A_{10}$) em perfis comportamentais, onde $\mathcal{P}$ representa o conjunto de perfis derivados. Subsequentemente, a função de recomendação $\Psi: \mathcal{P} \rightarrow \mathcal{S}$ mapeia cada perfil comportamental para estratégias pedagógicas personalizadas baseadas em evidências [8-16], onde $\mathcal{S}$ representa o conjunto de estratégias disponíveis.

IV. RESULTADOS

A. Desempenho do Modelo

O modelo atingiu acurácia de 100% em $\mathcal{D}_{\text{test}}$ ($N_{\text{test}} = 211$):

$$\text{Acc} = \frac{TP + TN}{N_{\text{test}}} = \frac{135 + 76}{211} = 1.00 \quad (7)$$

Métricas por classe (Tabela III):

$$P_i = R_i = F1_i = 1.00, \quad \forall i \in \{0, 1\} \quad (8)$$

onde P (precisão), R (recall) e $F1$ (F1-score) são perfeitos para ambas as classes.

TABLE III
RELATÓRIO DE CLASSIFICAÇÃO NO CONJUNTO DE TESTE

Classe	Precisão	Recall	F1-score	Suporte
0 (Ausente)	1,00	1,00	1,00	76
1 (Presente)	1,00	1,00	1,00	135
Acurácia	1,00 (211 amostras)			
Macro avg	1,00	1,00	1,00	211
Weighted avg	1,00	1,00	1,00	211

A matriz de confusão (Figura 6) confirma separação perfeita: $FP = FN = 0$.




Fig. 6. Matriz de confusão para o conjunto de teste.

B. Análise das Predições

As probabilidades preditas demonstram alta confiança: $P(y = 1|x) \approx 1$ para a maioria das amostras (Tabela IV).

TABLE IV
EXEMPLO DE PROBABILIDADES PREVISTAS PELO MODELO

Amostra	Probabilidade de TEA
1	0,9999986
2	0,9989839
3	0,9999999
8	0,9994163

C. Camada Interpretável e Perfil Comportamental

A camada interpretável mapeia respostas ($A1, \dots, A10$) em perfis comportamentais e estratégias pedagógicas baseadas em evidências. Para dificuldades de interação social (A1-A2), recomenda-se posicionamento na altura dos olhos, uso de objetos atrativos e reforço positivo [8]. Em comunicação gestual (A3), as estratégias incluem imitação, atenção compartilhada e reforço de gestos funcionais [9]. Para iniciação social (A4), sugere-se role-play, modelagem de saudações e integração às rotinas diárias [10].

Quanto à imaginação (A5), propõe-se dramaturgia com ambientes multi-sensoriais, fantoches e estruturação lúdica [11]. Para atenção conjunta (A6), utiliza-se recipiente com objetos surpresa e modelagem de foco com expressões faciais [12]. Em empatia social (A7), as abordagens envolvem cartões de emoção, histórias sociais e videomodelagem [13].

Para linguagem atípica (A8), recomenda-se aprendizado baseado em jogos, estimulação sensorial e atividades repetitivas [14]. Em comunicação não verbal (A9), as técnicas incluem modelagem, imitação, uso de espelhos e jogos [15]. Por fim, para atenção atípica (A10), sugere-se uso de interesses especiais, rotinas consistentes e promoção de estados de fluxo [16]. A implementação individualizada dessas estratégias contribui significativamente para o desenvolvimento sociocomunicativo de crianças com traços de TEA.

D. Explicabilidade do modelo

Para tornar as decisões do modelo mais transparentes e compreensíveis para profissionais da saúde e educadores, foram aplicadas técnicas de explicabilidade, incluindo SHAP (SHapley Additive exPlanations) e LIME (Local Interpretable Model-agnostic Explanations). Estas ferramentas permitem identificar quais variáveis mais influenciam as predições do modelo e como cada caso específico é classificado.

O SHAP fundamenta-se na teoria dos jogos cooperativos, onde o valor de Shapley para uma feature i é definido como:

$$\phi_i = \sum_{S \subseteq F \setminus i} \frac{|S|!(|F| - |S| - 1)!}{|F|!} [f(S \cup i) - f(S)] \quad (9)$$

onde F é o conjunto de todas as features, S é um subconjunto de features que não contém i , e $f(S)$ representa o valor esperado da predição do modelo condicionado às variáveis presentes em S .

A predição do modelo pode ser decomposta como a soma do valor base com os valores SHAP individuais:

$$f(\mathbf{x}) = \mathbb{E}[f(\mathbf{x})] + \sum_{i=1}^M \phi_i \quad (10)$$

onde $\mathbb{E}[f(X)]$ corresponde ao valor esperado da saída do modelo sobre a distribuição dos dados.

A importância global de cada feature é calculada como a média dos valores absolutos de SHAP sobre todas as amostras do conjunto de teste:

$$\bar{\phi}_i = \frac{1}{N_{\text{test}}} \sum_{j=1}^{N_{\text{test}}} |\phi_i^{(j)}| \quad (11)$$

Enquanto o SHAP fornece uma visão global e consistente das contribuições das features, o LIME aproxima localmente o modelo complexo f por um modelo interpretável g na vizinhança da amostra $\mathbf{x}$:

$$\xi(\mathbf{x}) = \arg \min_{g \in G} \mathcal{L}(f, g, \pi_{\mathbf{x}}) + \Omega(g) \quad (12)$$

onde $\mathcal{L}$ é a função de perda que mede a fidelidade local de g em relação a f , $\pi_{\mathbf{x}}$ define a distribuição de vizinhança em torno de $\mathbf{x}$, e $\Omega(g)$ é um termo de regularização que penaliza a complexidade do modelo interpretável.

A Figura 7 mostra os valores SHAP individuais, onde a cor vermelha indica valores altos da feature (presença da dificuldade) e a azul valores baixos (ausência). As variáveis comportamentais com maior impacto positivo são A10 (atenção atípica), A7 (empatia social) e A5 (imaginação), indicando que valores elevados dessas dificuldades contribuem significativamente para a classificação positiva. As demais variáveis comportamentais também apresentam impacto expressivo.

Entre as características individuais, Sexo destaca-se com o maior impacto, seguido por Idade com relevância moderada. Já Etnia, Icterícia e Histórico familiar de TEA apresentam valor SHAP próximo de zero, indicando menor relevância para as decisões do modelo.



Fig. 7. Valores SHAP individuais por variável sobre o impacto de cada feature na saída do modelo.

A Figura 8 mostra os valores SHAP médios. A variável Sexo tem o maior impacto (0,07), seguida por A10 (0,05), A7 (0,05), A5 (0,045), A8 (0,04), A6 (0,035), A9 (0,03), A2 (0,025), A4

(0,02) e Idade (0,018). Variáveis demográficas como Etnia, Icterícia e Histórico familiar de TEA apresentaram impacto próximo de zero.




Fig. 8. Gráfico de barras da importância global das variáveis com base nos valores SHAP médios.

A Figura 9 apresenta a explicação LIME para uma amostra do teste, classificada com aproximadamente 99% de probabilidade para TEA. Variáveis como A4, A10, A6, A2 e A7 contribuíram positivamente para essa decisão, enquanto A3, A9, A8, Idade e A5 tiveram influência negativa, sendo a classificação final determinada pelo predomínio das contribuições positivas.




Fig. 9. Visualização LIME da explicação local para uma amostra do conjunto de teste.

A combinação de SHAP e LIME mostrou que o modelo prioriza características comportamentais, especialmente A10, A7 e A5, com impacto próximo de zero para variáveis demográficas como Etnia e Icterícia. A alta confiança do modelo (probabilidade 1,00) torna a ferramenta mais transparente para profissionais da educação e saúde.

V. CONCLUSÃO

Este estudo apresentou um sistema inteligente para triagem de TEA combinando MLP com camada interpretável para recomendações pedagógicas personalizadas, demonstrando potencial como ferramenta de suporte clínico e educacional.

No entanto, é necessário reconhecer as limitações do estudo. O desempenho alcançado (100% de acurácia, precisão, recall e F1-score), embora matematicamente correto nos dados analisados, é atípico em tarefas clínicas e deve ser interpretado com cautela. Este resultado pode estar sujeito a overfitting, vazamento de dados (*data leakage*) e desbalanceamento das classes (69,1% de casos positivos mesmo utilizando *class_weight*). Diante dessas limitações, os resultados devem ser considerados como promissores, porém preliminares, e o modelo não substitui a avaliação clínica especializada.

Como trabalhos futuros, propõe-se validação em coortes multicêntricas independentes, expansão de estratégias baseadas em diretrizes clínicas atualizadas e desenvolvimento de interface amigável para uso por profissionais da educação e saúde.

DECLARAÇÃO DE USO DE INTELIGÊNCIA ARTIFICIAL

Em conformidade com as diretrizes de integridade científica e boas práticas acadêmicas recomendadas pela CAPES, os autores declaram que utilizaram a ferramenta DeepSeek para auxiliar na pesquisa de estratégias educacionais baseadas em literatura, aperfeiçoamento da linguagem e criação de tabelas. Todo o conteúdo foi revisado e editado pelos autores, que assumem total responsabilidade pelo trabalho final.

AGRADECIMENTOS

Os autores agradecem à disciplina de Redes Neurais do curso de Engenharia de Software da Universidade Federal Rural do Semi-Árido (UFERSA), no âmbito da qual este trabalho foi desenvolvido.

REFERENCES

- [1] SILVA, C. C.; ELIAS, L. C. S. Instrumentos de avaliação no transtorno do espectro autista: uma revisão sistemática. *Revista Avaliação Psicológica*, v. 19, n. 2, p. 189-197, 2020.
- [2] KOEGEL, Lynn Kern et al. The importance of early identification and intervention for children with or at risk for autism spectrum disorders. *International Journal of Speech-Language Pathology*, v. 16, n. 1, p. 50-56, 2014.
- [3] LINDLY, O. J.; ZUCKERMAN, K. E.; KUHLETHAU, K. A. Healthcare access and services use among US children with autism spectrum disorder. *Autism*, v. 23, n. 6, p. 1419-1430, 2019.
- [4] ANAGNOSTOPOULOU, Panagiota et al. Artificial intelligence in autism assessment. *International Journal of Emerging Technologies in Learning (IJET)*, v. 15, n. 6, p. 95-107, 2020.
- [5] FRANCESE, Rita; YANG, Xiaomin. Supporting autism spectrum disorder screening and intervention with machine learning and wearables: a systematic literature review. *Complex & Intelligent Systems*, v. 8, n. 5, p. 3659-3674, 2022.
- [6] THABTAH, Fadi. Autism spectrum disorder screening: machine learning adaptation and DSM-5 fulfillment. In: *Proceedings of the 1st International Conference on Medical and Health Informatics*, p. 1-6, 2017.
- [7] WALL, Dennis P. et al. Use of artificial intelligence to shorten the behavioral diagnosis of autism. *PLoS ONE*, v. 7, n. 8, p. e43855, 2012.
- [8] N. Adriaenssens, "Using an elicited orienting response and respondent conditioning to increase eye contact in response to a name call in children with autism", M.S. thesis, Florida Institute of Technology, Melbourne, FL, 2019.
- [9] M. G. Logrieco, L. Casula, S. Guerrero, M. Fasolo, G. Valeri, S. Vicari, and E. Annechini, "Nonverbal skills evolution in children with autism spectrum disorder one year post-diagnosis," *Children*, vol. 11, no. 12, pp. 1520, 2024.
- [10] D. J. Dsouza and R. Kaur, "From core to steps: Development and validation of next-level interactive social pragmatic interventions and responsive engagement for children with autism, through trackable intervention model," *MethodsX*, pp. 103663, 2025.
- [11] J. Beadle-Brown, D. Wilkinson, L. Richardson, N. Shaughnessy, M. Trimmingham, J. Leigh, B. Whelton, and J. Himmerich, "Imagining autism: Feasibility of a drama-based intervention on the social, communicative and imaginative behaviour of children with autism," *Autism*, vol. 22, no. 8, pp. 915-927, 2018.
- [12] G. Davies, "Attention Autism," Whittington Hospital NHS. [Online]. Available: <https://www.whittington.nhs.uk/default.asp?c=44644&print=1>. Accessed: Apr. 17, 2026.
- [13] Advanced Autism Services, "Supporting social and emotional development in children with autism," Jun. 27, 2025. [Online]. Available: <https://www.advancedautism.com/post/supporting-social-and-emotional-development-in-children-with-autism>. Accessed: Apr. 17, 2026.
- [14] R. Nordin, M. Marzuki, and R. Aboo Bakar, "I-M-A-N approach: A creative method to teach autistic children verbal communication," in *Melaka International Intellectual Exposition 2024 (MIIEX'24)*, Melaka, Malaysia, 2024, pp. 507-510.
- [15] N. O. M. Mohammed, A. A. Hassan, "The effectiveness of a proposed training program to develop nonverbal communication skills in children with autism spectrum disorder," *Sulaimani Journal for Humanities*, vol. 2, no. 2, pp. 231-254, 2025.
- [16] "Supporting monotropic thinkers: Creating environments where focus can flourish," *Reframing Autism*, Oct. 19, 2025. [Online]. Available: <https://reframingautism.org.au/supporting-monotropic-thinkers-creating-environments-where-focus-can-flourish/>. Accessed: Apr. 17, 2026.