



10º Encontro de Ensino Pesquisa e Extensão

Patrocínio, MG, outubro de 2023

APLICAÇÃO DE TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL NA IDENTIFICAÇÃO DE PADRÕES DE AGRESSIVIDADE EM PACIENTES COM TRANSTORNO DO DÉFICIT DE ATENÇÃO COM HIPERATIVIDADE

Gabriel Cardoso Elias, Danielli Araújo Lima
Instituto Federal do Triângulo Mineiro (IFTM) Campus Patrocínio
gabriel.elias@estudante.iftm.edu.br, danielli@iftm.edu.br

Modalidade: Pesquisa
Formato: Artigo Completo

Resumo: Detectar agressividade em pacientes com Transtorno de Déficit de Atenção com Hiperatividade (TDAH) é um desafio na saúde e psiquiatria. Este estudo usa inteligência artificial para identificar esses padrões, visando aprimorar a compreensão e o acompanhamento desses pacientes. A pesquisa visa melhorar estratégias terapêuticas, dado o impacto da falta de detecção precoce de agressividade em pacientes com TDAH na saúde mental. A Inteligência Artificial é crucial, com vários algoritmos em investigação. Destacando que o algoritmo mais preciso foi a RNA, com 93,7% de acerto, propomos uma aplicação prática: inserir dados do paciente em um formulário e processá-los com o algoritmo de RNA de alta precisão para prever o comportamento agressivo em pacientes com TDAH. Esta abordagem pode ser promissora, pois beneficia a qualidade de vida dos pacientes e avança a saúde mental, melhorando diagnóstico e tratamento dos pacientes.

Palavras-chaves: Transtorno de Déficit de Atenção com Hiperatividade; Comportamento Agressivo; Inteligência Artificial; Psiquiatria; Diagnóstico em Pacientes.

Introdução

O Transtorno de Déficit de Atenção com Hiperatividade (TDAH) é uma condição complexa que afeta indivíduos desde a infância até a idade adulta, frequentemente manifestando comportamentos agressivos (ROHDE; BENCZIK, 1999). Esta condição traz consigo uma série de desafios significativos que impactam a qualidade de vida desses

pacientes. A detecção precoce e a gestão adequada da agressividade são essenciais para mitigar as consequências adversas na saúde mental e no bem-estar desses indivíduos (BARROS; SILVA, 2006). O TDAH pode causar uma série de impactos significativos na vida de uma pessoa, que variam de dificuldades acadêmicas e problemas de relacionamento a questões de autoestima, dificuldades no trabalho e impactos na qualidade de vida em geral. Esses desafios podem ser especialmente pronunciados quando se trata de lidar com comportamentos agressivos associados ao TDAH (SOUZA NUNES; WERLANG, 2008). Os autores da pesquisa (ROHDE; BENCZIK, 1999) relataram que os médicos chamam de comorbidade à ocorrência, em conjunto, de dois ou mais problemas de saúde mental. Por exemplo, cerca de 50% das crianças e adolescentes com TDAH também apresentam problemas de comportamento como agressividade, mentiras, roubo, comportamento de oposição ou de desafio às regras e aos pedidos dos adultos (MAIA; CONFORTIN, 2015).

Este estudo aborda a aplicação de técnicas avançadas de Inteligência Artificial (IA) para identificar e compreender padrões de comportamento agressivo em pacientes com TDAH. O objetivo principal é aprimorar a compreensão e o monitoramento desses pacientes, proporcionando uma base sólida para o desenvolvimento de estratégias de tratamento mais eficazes e direcionadas. O uso da IA neste contexto representa uma abordagem promissora para melhorar o diagnóstico e o tratamento do TDAH, contribuindo para uma melhoria significativa na qualidade de vida desses indivíduos e no avanço da área de saúde mental como um todo. Este estudo enfatiza a importância de uma abordagem inovadora e tecnológica na gestão do TDAH, visando oferecer assistência mais eficaz aos pacientes e uma melhor compreensão de suas necessidades clínicas.

A motivação para nosso estudo advém de que a falta de detecção precoce da agressividade em pacientes com TDAH pode acarretar consequências adversas para a saúde mental e o bem-estar desses indivíduos, tornando o uso da IA uma abordagem promissora para aprimorar o diagnóstico e o tratamento. Neste artigo, apresentamos nossa proposta, embasamento teórico, metodologia e resultados experimentais relacionados à aplicação de IA na identificação de agressividade em pacientes com TDAH, com o intuito de contribuir significativamente para a qualidade de vida desses pacientes e para o avanço do campo da saúde mental.

Fundamentação Teórica

O Transtorno do Déficit de Atenção com Hiperatividade (TDAH) é um distúrbio de origem neurobiológica com influências genéticas, manifestando-se tipicamente na infância e persistindo ao longo da vida. Suas principais características incluem sintomas de desatenção, inquietude e impulsividade. Este transtorno é conhecido por diferentes nomes, como Distúrbio do Déficit de Atenção¹ (DDA), Atencion Deficit Disorder ADD, Attention deficit hyperactivity disorder (ADHD) ou Attention deficit/Hyperactivity disorder AD/HD em inglês.

Neste contexto, a compreensão aprofundada do TDAH torna-se essencial, especialmente no que se refere à identificação de padrões de agressividade em pacientes afetados. A agressividade é um traço complexo e variável entre indivíduos, mas quando associada ao TDAH, assume uma relevância particular, constituindo um desafio adicional tanto para os pacientes como para os profissionais de saúde que os acompanham. A identificação precisa de padrões de agressividade em pacientes com TDAH é fundamental para adaptar os tratamentos, indicando a necessidade de intervenções médicas e terapêuticas mais específicas.

O Aprendizado de Máquina (AM), também chamado Machine Learning (ML) em inglês, é um conjunto de algoritmos que permite que sistemas ou programas de computador aprendam e melhorem automaticamente com base em dados, dispensando a necessidade de programação específica (ALVES; LIMA, 2018). Em vez de seguir regras fixas, esses algoritmos identificam padrões e tomam decisões com base nos dados de treinamento (SOUZA; LIMA, 2023). O Aprendizado de Máquina faz parte da IA e é uma peça crucial desse campo mais amplo. Ele capacita sistemas a aprenderem com dados, aprimorando seu desempenho em tarefas específicas (LIMA; FERREIRA; SILVA, 2021). A IA engloba diversas técnicas, como compreensão de linguagem natural e reconhecimento de padrões, e o Aprendizado de Máquina é uma delas. No contexto da IA, o ML representa a capacidade dos sistemas de adquirir conhecimento e melhorar com a experiência, adaptando-se a novas informações e situações (DORNELAS; LIMA, 2023). No entanto, a IA não se limita ao ML; inclui outras abordagens, como lógica simbólica e visão computacional, que não dependem exclusivamente do treinamento

¹Manual da Associação Brasileira do Deficit de Atenção, <https://abda.org.br/>, acesso em setembro de 2023.

com dados. O ML é um conjunto de algoritmos que permite que sistemas aprendam com dados e melhorem seu desempenho em tarefas específicas, sendo uma parte essencial da IA moderna. Neste trabalho optamos por investigar 7 algoritmos de ML para a classificação do TDAH em pacientes:

1. Decision Tree Learner (DTL): O DTL é um algoritmo que cria uma estrutura em forma de árvore de decisão, na qual cada nó representa uma decisão com base em um atributo específico. Ele é usado para classificação e regressão, dividindo os dados em conjuntos menores com base nas características mais relevantes.
2. Gradient Boosted Learner (GBL): O GBL é um algoritmo de aprendizado supervisionado que combina várias árvores de decisão fracas para criar um modelo forte. Ele funciona treinando iterativamente árvores de decisão, dando mais peso aos exemplos classificados incorretamente em cada iteração, melhorando gradualmente o desempenho do modelo.
3. Multilayer Perceptron Learning (MLP): O MLP é um tipo de rede neural artificial composta por várias camadas de neurônios interconectados. Ele é utilizado para tarefas de classificação e regressão e é capaz de aprender relações complexas nos dados, sendo uma das técnicas mais utilizadas em deep learning.
4. Naive Bayes Learner (NBL): O NBL é um algoritmo de classificação que se baseia no teorema de Bayes para calcular a probabilidade de uma instância pertencer a uma classe específica. Ele assume que as características são independentes entre si, o que pode ser uma simplificação útil em muitos cenários.
5. Neural Network Learner (NNL): O NNL é uma abordagem de aprendizado de máquina baseada em redes neurais artificiais, que consistem em camadas de neurônios interconectados. Ele é usado em uma ampla gama de tarefas de aprendizado profundo, incluindo visão computacional, processamento de linguagem natural e reconhecimento de padrões.
6. Random Forest Learner (RFL): O RFL é uma extensão do algoritmo de árvore de decisão que cria múltiplas árvores de decisão durante o treinamento e combina seus resultados. Isso ajuda a reduzir o overfitting e aumentar a precisão do modelo, tornando-o robusto em muitos cenários.

7. Support Vector Machine Learning (SVM): O SVM é um algoritmo de aprendizado supervisionado usado para classificação e regressão. Ele encontra um hiperplano de decisão que melhor separa os dados em diferentes classes, maximizando a margem entre as classes. O SVM é eficaz em dados de alta dimensão e em problemas de classificação binária e multi-classe.

No estudo (CAO et al., 2006), os autores usaram uma nova abordagem de homogeneidade regional para analisar dados de ressonância magnética funcional em repouso de meninos com TDAH. Os autores observaram uma redução da homogeneidade regional em circuitos frontais-estriatais-cerebelares, mas aumento principalmente no córtex occipital. Esses achados apoiam a hipótese de circuitos anormais no TDAH. A abordagem de homogeneidade regional pode ser útil para explorar a fisiopatologia do TDAH.

Neste contexto, segundo (CAO et al., 2006), o padrão descrito no atributo “Med: Naive/nonNaive” indica se o paciente recebeu previamente ou não uma medição específica. Quando se trata das medidas de QI (Quociente de Inteligência), existem duas componentes importantes: o VIQ (Quociente de Inteligência Verbal) avalia a capacidade do indivíduo de trabalhar com símbolos abstratos, memória verbal e fluência, enquanto o PIQ (Quociente de Inteligência de Performance) mede a habilidade de funcionar rapidamente em situações concretas e as habilidades visuo-espaciais. Em casos onde o VIQ e o PIQ apresentam uma diferença estatisticamente significativa, é preferível fornecer essas pontuações separadamente em vez de usar o TIQ (Quociente de Inteligência Total), que é a média das duas pontuações. Isso reflete a importância de reconhecer que tanto o VIQ quanto o PIQ são componentes cruciais da pontuação “real” de QI.

Além disso, as siglas “AD” e “HI” indicam dois subtipos do TDAH (Transtorno do Déficit de Atenção com Hiperatividade): “AD” representa o subtipo de “Atenção Desatenta”, caracterizado por sintomas de desatenção, enquanto “HI” representa o subtipo de “Hiperatividade-Impulsividade”, que se concentra em sintomas de hiperatividade e impulsividade. A detecção precoce da agressividade em pacientes com TDAH pode ser decisiva para evitar consequências adversas, como dificuldades interpessoais, desafios acadêmicos e até mesmo a exposição a comportamentos de risco. Portanto, compreender a relação entre o TDAH e a agressividade é essencial para desenvolver estratégias de tratamento mais eficazes e direcionadas (CAO et al., 2006).

Materiais e métodos

Os materiais usados neste trabalho incluem o conjunto de dados encontrado no repositório GitHub², porém, é importante destacar que sua fonte original é referenciada no artigo (CAO et al., 2006). Este conjunto de dados compreende informações clínicas e comportamentais de pacientes diagnosticados com TDAH. A categoria (classe) “Agressão” é utilizada para classificar se o paciente manifesta comportamento agressivo ou não. Priorizamos uma abordagem ética na manipulação desses dados, visando preservar a integridade das informações e promover um uso responsável da aplicação resultante. Durante toda a pesquisa, adotamos rigorosas considerações éticas, mantendo um compromisso firme com a proteção da privacidade e dos direitos dos pacientes, mesmo quando os dados não incluem informações sensíveis. Além disso, o KNIME Analytics Platform foi usado para a realização dos experimentos para encontrar o melhor algoritmo de classificação de dados.

Este estudo pode ser classificado como um estudo de pesquisa experimental, pois envolve a aplicação de técnicas de inteligência artificial para identificar padrões de agressividade em pacientes com Transtorno de Déficit de Atenção com Hiperatividade (TDAH) e avaliar a eficácia dessas técnicas. O estudo possui uma natureza aplicada, uma vez que busca aplicar os conhecimentos teóricos e tecnológicos da inteligência artificial para resolver um problema prático, ou seja, a detecção de agressividade em pacientes com TDAH. Quanto à análise de dados, este estudo utiliza técnicas de análise de dados quantitativa, já que se baseia em algoritmos de inteligência artificial para processar informações clínicas e comportamentais dos pacientes e gerar previsões quantitativas sobre o comportamento agressivo.

Quanto aos procedimentos metodológicos, o tratamento dos dados desempenhou um papel fundamental. Inicialmente, procedemos com a normalização dos dados, padronizando as variáveis para um intervalo padrão, o que facilitou a comparação e análise das características. Além disso, como parte desse processo, realizamos a substituição das categorias “YES” e “NO” por 0 e 1, respectivamente, bem como as categorias “Male” e “Female” também foram substituídas por 0 e 1. Essas codificações binárias

²A data set that describes phenotypic information of children with Attention Deficit Hyperactivity Disorder (ADHD). Data set only included variables of interest, consisting of 221 subjects and eight variables. Link de acesso: <https://github.com/rahmarid/dataset>.

foram implementadas com o propósito de simplificar a interpretação e viabilizar o treinamento do modelo de IA. Essas operações foram de importância crucial para garantir a uniformidade e acessibilidade dos dados, permitindo análises subsequentes de maneira precisa e eficiente.

Resultados experimentais

Nesta seção, serão exibidos os resultados obtidos por meio da avaliação de sete algoritmos de aprendizado de máquina no contexto da detecção de padrões de agressividade em pacientes com TDAH. Os algoritmos testados incluíram Decision Tree Learner (DTL), Gradient Boosted Learner (GBL), Multilayer Perceptron Learning (MLP), Naive Bayes Learner (NBL), Neural Network Learner (NNL), Random Forest Learner (RFL) e Support Vector Machine Learning (SVM). Cada algoritmo foi submetido a testes detalhados utilizando a plataforma KNIME Analytics Platform.

Os resultados desses testes proporcionaram informações valiosas sobre o desempenho de cada modelo na detecção de agressividade em pacientes com TDAH, evidenciando suas respectivas taxas de acerto: Decision Tree Learner com 79,6%, Gradient Boosted com 85,5%, MLP Learning com 87,4%, Naive Bayes com 81,9%, Neural Network com impressionantes 93,7%, Random Forest com 87,3% e SVM Learning com 86,9%. Nas Figuras 1(a), 1(b), 1(c), 1(d), 1(e), 1(f) e 1(g), estão representações visuais dos resultados gerados na plataforma KNIME. Essas imagens oferecem uma análise detalhada das capacidades de cada algoritmo neste contexto, facilitando a compreensão dos dados.

Desenvolvimento

Este estudo tem como objetivo desenvolver um modelo de IA para identificar agressividade em pacientes com TDAH, por meio da análise de dados clínicos e comportamentais, com o propósito de aprimorar o diagnóstico e tratamento do TDAH e promover uma compreensão mais profunda da relação entre a agressividade e esse transtorno neuropsiquiátrico. O sistema resultante visa auxiliar profissionais de saúde a realizar diagnósticos e tratamentos mais precisos, com o intuito de substancialmente melhorar

#	Row...	TruePositives Number (integer)	FalsePositives Number (integer)	TrueNegatives Number (integer)	FalseNegatives Number (integer)	Recall Number (double)	Precision Number (double)	Sensitivity Number (double)	Specificity Number (double)	F-measure Number (double)	Accuracy Number (double)	Cohen's kappa Number (double)
1	No	169	21	7	24	0.876	0.889	0.876	0.25	0.883	0	0
2	Yes	7	24	169	21	0.25	0.226	0.25	0.876	0.237	0	0
3	Overall	0	0	0	0	0	0	0	0	0	0.796	0.12

(a) Métricas para Decision Tree Learner.

#	Row...	TruePositives Number (integer)	FalsePositives Number (integer)	TrueNegatives Number (integer)	FalseNegatives Number (integer)	Recall Number (double)	Precision Number (double)	Sensitivity Number (double)	Specificity Number (double)	F-measure Number (double)	Accuracy Number (double)	Cohen's kappa Number (double)
1	No	180	19	9	13	0.933	0.905	0.933	0.321	0.918	0	0
2	Yes	9	13	180	19	0.321	0.409	0.321	0.933	0.36	0	0
3	Overall	0	0	0	0	0	0	0	0	0	0.855	0.28

(b) Métricas para Gradient Boosted Learner.

#	Row...	TruePositives Number (integer)	FalsePositives Number (integer)	TrueNegatives Number (integer)	FalseNegatives Number (integer)	Recall Number (double)	Precision Number (double)	Sensitivity Number (double)	Specificity Number (double)	F-measure Number (double)	Accuracy Number (double)	Cohen's kappa Number (double)
1	No	97	14	0	0	1	0.874	1	0	0.933	0	0
2	Yes	0	0	97	14	0	0	0	1	0	0	0
3	Overall	0	0	0	0	0	0	0	0	0	0.874	0

(c) Métricas para Multilayer Perceptron Learner.

#	Row...	TruePositives Number (integer)	FalsePositives Number (integer)	TrueNegatives Number (integer)	FalseNegatives Number (integer)	Recall Number (double)	Precision Number (double)	Sensitivity Number (double)	Specificity Number (double)	F-measure Number (double)	Accuracy Number (double)	Cohen's kappa Number (double)
1	No	165	12	16	28	0.855	0.932	0.855	0.571	0.892	0	0
2	Yes	16	28	165	12	0.571	0.364	0.571	0.855	0.444	0	0
3	Overall	0	0	0	0	0	0	0	0	0	0.819	0.343

(d) Métricas para Naive Bayes Learner.

#	Row...	TruePositives Number (integer)	FalsePositives Number (integer)	TrueNegatives Number (integer)	FalseNegatives Number (integer)	Recall Number (double)	Precision Number (double)	Sensitivity Number (double)	Specificity Number (double)	F-measure Number (double)	Accuracy Number (double)	Cohen's kappa Number (double)
1	No	190	11	17	3	0.984	0.945	0.984	0.607	0.964	0	0
2	Yes	17	3	190	11	0.607	0.85	0.607	0.984	0.708	0	0
3	Overall	0	0	0	0	0	0	0	0	0	0.937	0.674

(e) Métricas para Neural Network Learner.

#	Row...	TruePositives Number (integer)	FalsePositives Number (integer)	TrueNegatives Number (integer)	FalseNegatives Number (integer)	Recall Number (double)	Precision Number (double)	Sensitivity Number (double)	Specificity Number (double)	F-measure Number (double)	Accuracy Number (double)	Cohen's kappa Number (double)
1	No	187	22	6	6	0.969	0.895	0.969	0.214	0.93	0	0
2	Yes	6	6	187	22	0.214	0.5	0.214	0.969	0.3	0	0
3	Overall	0	0	0	0	0	0	0	0	0	0.873	0.242

(f) Métricas para Random Forest Learner.

#	Row...	TruePositives Number (integer)	FalsePositives Number (integer)	TrueNegatives Number (integer)	FalseNegatives Number (integer)	Recall Number (double)	Precision Number (double)	Sensitivity Number (double)	Specificity Number (double)	F-measure Number (double)	Accuracy Number (double)	Cohen's kappa Number (double)
1	No	192	28	0	0	0.995	0.873	0.995	0	0.93	0	0
2	Yes	0	1	192	28	0	0	0	0.995	0	0	0
3	Overall	0	0	0	0	0	0	0	0	0	0.869	-0.009

(g) Métricas para Support Vector Machine Learner.

Figura 1: Medidas para mensurar a acurácia e demais estatísticas dos algoritmos de mineração de dados.

a qualidade de vida e o bem-estar dos pacientes.

O conjunto de dados utilizado neste estudo foi encontrado no repositório GitHub, porém, é importante destacar que sua fonte original é referenciada no artigo (CAO et al., 2006) Este conjunto de dados contém informações clínicas e comportamentais de pacientes diagnosticados com Transtorno de Déficit de Atenção e Hiperatividade (TDAH). Priorizamos o tratamento ético dos dados para garantir a integridade dos dados e promover o uso responsável da aplicação resultante. Além disso, respeitamos considerações éticas ao longo da pesquisa, mantendo um compromisso sólido com a proteção da privacidade e dos direitos dos pacientes, mesmo quando os dados não contêm informações sensíveis.

Desenvolvemos uma aplicação web neste estudo, a qual emprega um modelo de IA baseado em uma rede neural para detectar agressividade em indivíduos com

TDAH. A escolha de utilizar uma Rede Neural como modelo de Inteligência Artificial é detalhada na seção de Resultados Experimentais, onde são apresentados os resultados que influenciaram essa seleção. O modelo de IA foi previamente treinado com dados clínicos e comportamentais de pacientes com TDAH, estabelecendo uma base sólida de conhecimento, com acurácia de 93.7%. Os usuários inserem informações do paciente por meio de um formulário HTML, e o software utiliza a rede neural treinada para prever a agressividade com base nos dados fornecidos. Esta abordagem busca melhorar o diagnóstico e tratamento do TDAH e proporcionar uma compreensão mais profunda da relação entre a agressividade e este transtorno neuropsiquiátrico.

A implementação da aplicação envolveu o desenvolvimento de uma interface web na qual os usuários inserem informações relacionadas a pacientes diagnosticados com TDAH, utilizando tecnologias web convencionais. Os dados inseridos na interface web foram processados com o auxílio de bibliotecas especializadas em aprendizado de máquina, como Scikit-Learn para pré-processamento e avaliação de desempenho, Pandas para organização e manipulação eficiente dos dados, TensorFlow para a construção e treinamento da Rede Neural, e NumPy para operações numéricas e manipulação de matrizes e tensores. Essas bibliotecas permitiram a análise e processamento dos dados inseridos, gerando previsões relacionadas à agressividade em pacientes com TDAH com base nas informações fornecidas pelos usuários.

A seguir, nas Figuras 2 e 3, serão apresentadas representações visuais do sistema desenvolvido para a detecção de padrões de agressividade em pacientes diagnosticados com Transtorno de Déficit de Atenção e Hiperatividade (TDAH). Na Figura 2, é exibida a seção do formulário, onde os usuários têm a capacidade de inserir informações detalhadas relacionadas aos pacientes com TDAH. Esta representação visual destaca a interface de coleta de dados, fundamental para a aquisição precisa das informações necessárias. Já na Figura 3, podemos observar a seção de resultados do sistema, onde são apresentadas as previsões geradas em relação à agressividade dos pacientes. Estas previsões são calculadas com base nas informações previamente fornecidas no formulário. A exibição visual das previsões desempenha um papel central na interpretação dos resultados gerados pelo sistema, facilitando a compreensão e análise das informações produzidas.

Preencha o formulário a seguir

Gender

AD
 Significa "Atenção Desatenta" (ou "Attention Deficit" em inglês). Esse subtipo é caracterizado principalmente por sintomas de desatenção, como dificuldade em prestar atenção a detalhes, cometer erros por descuido, ter dificuldade em manter o foco em tarefas, ser facilmente distraído e esquecer atividades cotidianas.

HI
 HI: Significa "Hiperatividade-Impulsividade" (ou "Hyperactivity-Impulsivity" em inglês). Esse subtipo é caracterizado principalmente por sintomas de hiperatividade e impulsividade. Os indivíduos com esse subtipo podem apresentar agitação constante, dificuldade em permanecer sentados, inquietação, impulsividade em suas ações e fala, interrupção de conversas ou atividades, bem como dificuldade em esperar sua vez.

Medication History
 Naive/nonNaive = Recebeu ou não anteriormente medição específica.

Perf IQ
 Performance IQ (PIQ) é sua capacidade de funcionar rapidamente em situações concretas, bem como suas habilidades visuo-espaciais.

Verb IQ
 Verbal IQ (VIQ) se refere à sua capacidade de trabalhar com símbolos abstratos, usando sua memória verbal e fluência. Isso inclui coisas que você aprendeu no passado e precisa lembrar.

Full IQ
 Full IQ (FIQ) se refere ao QI Total, ou a média sempre usada para representar QI.

☐ I accept the [terms of use](#)

Desenvolvido por [Gabriel Cardoso](#)

Figura 2: Aplicação web desenvolvida para gerar a classificação de dados.

Conclusões

Este estudo se concentrou na detecção de agressividade em pacientes com Transtorno de Déficit de Atenção com Hiperatividade (TDAH) usando Inteligência Artificial (IA). A detecção precoce e o acompanhamento da agressividade são essenciais para melhorar a qualidade de vida desses pacientes e evitar impactos negativos em sua saúde mental. A pesquisa propôs o desenvolvimento de uma aplicação web baseada em IA, treinada com dados clínicos, para auxiliar no diagnóstico e tratamento personalizado. Os resultados mostraram que a IA, especialmente uma Rede Neural, alcançou alta precisão na detecção de agressividade em pacientes com TDAH, neste caso, 93.7% de acurácia.

Informações do Formulário

Gênero: Male
Déficit de Atenção: 41
Hiperatividade-Impulsividade: 35
Histórico de Medicação: Naive
PerfIQ: 89
VerbIQ: 64
FullIQ: 115

Previsões

Previsão de Agressividade Contínua: [[0.45571026]]
Previsão de Agressividade Binária: [['No']]

[Voltar para o Formulário](#)

Desenvolvido por **Gabriel Cardoso**

Figura 3: Tela de previsão gerada pela rede neural artificial.

Este estudo representa um avanço na área de saúde neuropsicológica, oferecendo uma abordagem tecnológica para melhorar o diagnóstico e tratamento de pacientes com TDAH. A aplicação da IA promete melhorar a qualidade de vida desses pacientes e contribuir para o progresso da psiquiatria, enfatizando a importância da adoção de novas tecnologias na busca por tratamentos mais eficazes e personalizados.

Para avançar neste campo, como trabalhos futuros é importante priorizar o aprimoramento tecnológico da aplicação de IA, incluindo otimizações no modelo de rede neural, a integração de dados clínicos abrangentes e melhorias na usabilidade da interface, especialmente para profissionais de saúde. A validação clínica por meio de estudos envolvendo médicos e pacientes é essencial. Ampliar o uso da IA para detectar agressividade em outras condições de saúde mental, como transtorno bipolar e transtorno de personalidade borderline, pode ter um impacto significativo. Desenvolver estratégias de intervenção personalizada, adaptadas às necessidades individuais dos pacientes com TDAH e agressividade, é promissor para melhorar o tratamento. Estudos de acompanhamento são cruciais para avaliar o impacto a longo prazo da detecção precoce e das intervenções personalizadas no TDAH e na redução da agressividade. Por fim, análises econômicas abrangentes são necessárias para avaliar os custos e benefícios da imple-

mentação de sistemas de IA na detecção de agressividade em pacientes com TDAH, considerando os impactos na saúde mental, nos custos de tratamento e na qualidade de vida.

Referências

- ALVES, F. B.; LIMA, D. A. Uso de la clasificación para el análisis y la minería de datos en la herramienta de enseñanza-aprendizaje Google Classroom. **Nuevas Ideas en Informática Educativa**, v. 4, p. 589–594, 2018.
- BARROS, P.; SILVA, F. B. N. Origem e manutenção do comportamento agressivo na infância e adolescência. **Revista Brasileira de Terapias Cognitivas**, Federação Brasileira de Terapias Cognitivas, v. 2, n. 1, p. 55–66, 2006.
- CAO, Q. et al. Abnormal neural activity in children with attention deficit hyperactivity disorder: a resting-state functional magnetic resonance imaging study. **Neuroreport**, LWW, v. 17, n. 10, p. 1033–1036, 2006.
- DORNELAS, R. S.; LIMA, D. A. Correlation Filters in Machine Learning Algorithms to Select Demographic and Individual Features for Autism Spectrum Disorder Diagnosis. **Journal of Data Science and Intelligent Systems**, 2023.
- LIMA, D. A.; FERREIRA, M. E. A.; SILVA, A. F. F. Machine learning and data visualization to evaluate a robotics and programming project targeted for women. **Journal of Intelligent & Robotic Systems**, Springer, v. 103, n. 1, p. 4, 2021.
- MAIA, M. I. R.; CONFORTIN, H. TDAH e aprendizagem: um desafio para a educação. **Revista Perspectiva**, v. 39, n. 148, p. 73–84, 2015.
- ROHDE, L. A. P.; BENCZIK, E. B. **Transtorno de déficit de atenção e hiperatividade. O que é? Como ajudar?** [S.l.]: Artes médicas sul, 1999.
- SOUZA, V. S.; LIMA, D. A. Identifying Risk Factors for Heart Failure: A Case Study Employing Data Mining Algorithms. **Journal of Data Science and Intelligent Systems**, 2023.
- SOUZA NUNES, M. M. de; WERLANG, B. S. G. Transtorno de déficit de atenção/hiperatividade e transtorno de conduta: aspectos familiares e escolares. **ConScientiae Saúde**, Universidade Nove de Julho, v. 7, n. 2, p. 207–216, 2008.