

## Aprendizado de máquina e rs-fMRI para o diagnóstico de TDAH: uma revisão sistemática

Alice Silva Mendonça, Igor Duarte Rodrigues

Saúde e Bem-Estar

Pesquisa

### Introdução

O Transtorno do Déficit de Atenção e Hiperatividade (TDAH) é um transtorno do neurodesenvolvimento comum, caracterizado, principalmente, por desatenção, impulsividade e hiperatividade. Apesar de sua alta prevalência, sua etiologia ainda é pouco explorada. O diagnóstico clínico ainda é predominantemente comportamental, o que dificulta a descoberta de biomarcadores confiáveis devido à heterogeneidade neurológica.

Nesse contexto, entretanto, a neuroimagem funcional tem se mostrado promissora. A ressonância magnética funcional (fMRI), especialmente em estado de repouso (rs-fMRI), permite mapear conexões cerebrais de forma não invasiva por meio do sinal BOLD (relacionado ao nível de oxigenação sanguínea). Aliada a técnicas de aprendizado de máquina, a rs-fMRI tem sido usada em estudos para realizar o diagnóstico do TDAH com maior precisão e apresenta grande potencial.

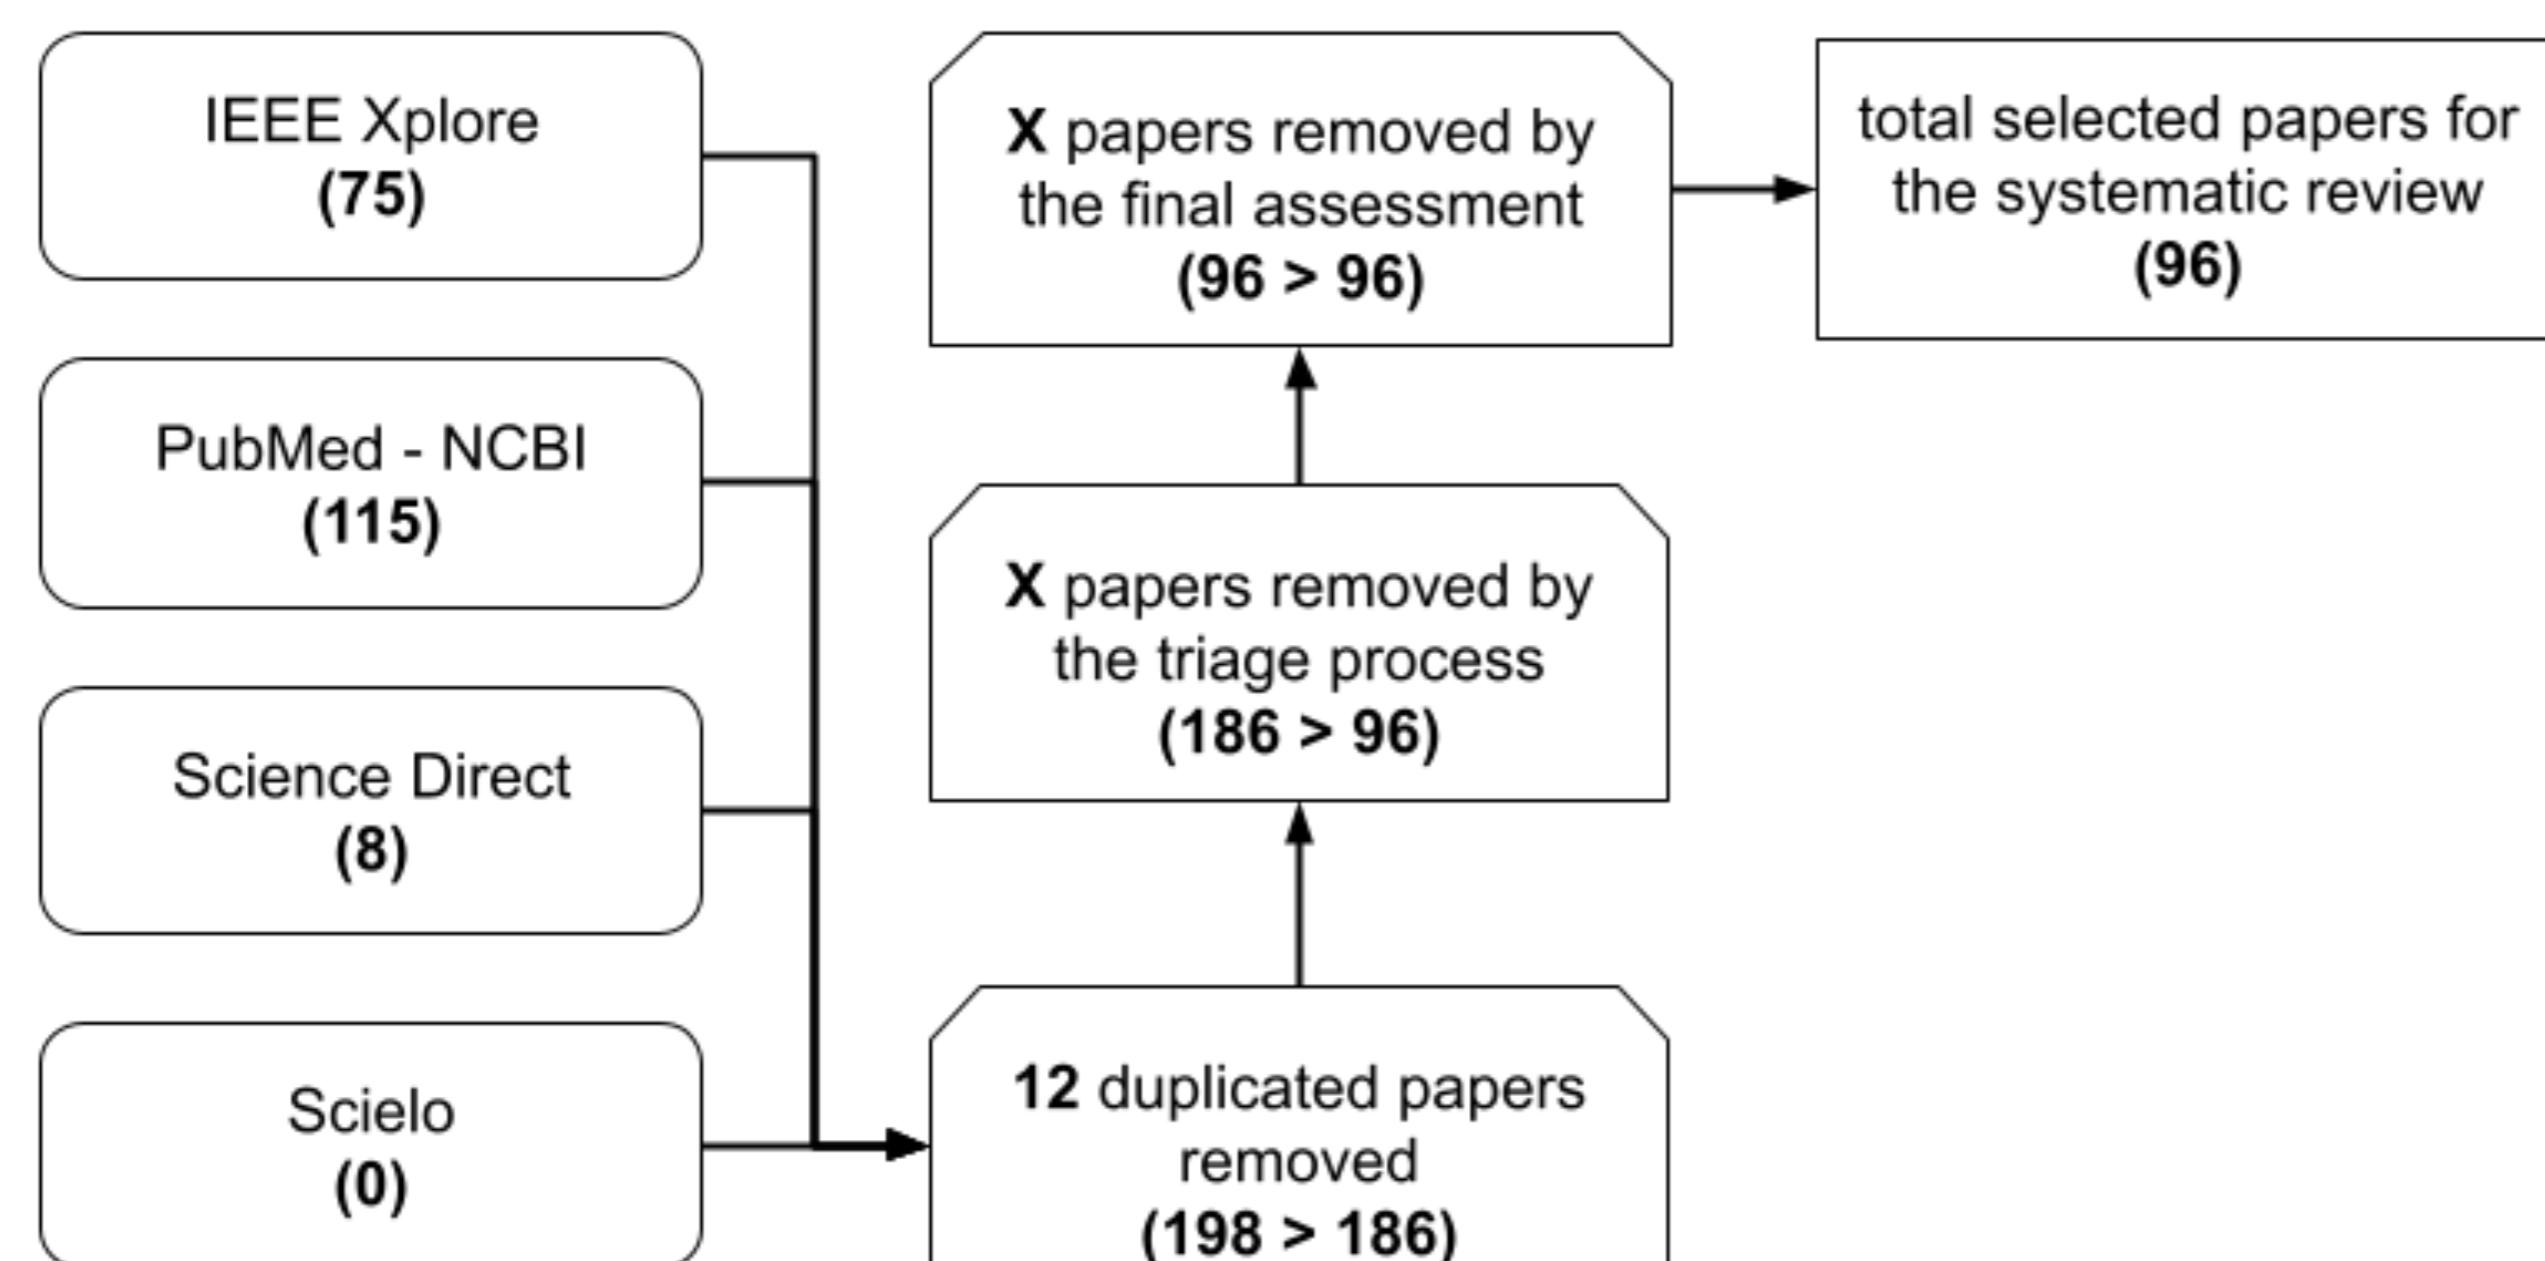
### Objetivos

O objetivo principal desta revisão sistemática é investigar e sintetizar as evidências científicas sobre o uso de técnicas de aprendizado de máquina aplicadas a dados de rs-fMRI no diagnóstico do TDAH.

Especificamente, pretende-se analisar os dados de fMRI utilizados, a extração de características e a definição de regiões de interesse (ROIs). Além disso, busca-se identificar os algoritmos de aprendizado de máquina mais frequentemente aplicados, avaliando suas configurações, estratégias de validação e métricas de desempenho.

Outro objetivo também é observar as regiões cerebrais mais frequentemente associadas ao TDAH nos resultados dos estudos. Ainda, a revisão procura avaliar a reprodutibilidade das pesquisas analisadas, considerando a disponibilização de código-fonte, dados abertos e o detalhamento metodológico fornecido pelos autores.

### Metodologia



### Apoio Financeiro

### Resultados

O pré-processamento dos dados utilizou majoritariamente pipelines padrão, como FSL e SPM. Para a definição de ROIs, os atlas AAL e Desikan-Killiany foram os mais comuns. Entre os algoritmos observados, Support Vector Machine (SVM) foi o mais aplicado – obtendo, ainda, os melhores desempenhos, com acurácia máxima de 98,04% –, seguido por redes neurais profundas (como DBN e CNN).

Outras métricas de desempenho, contudo, foram pouco relatadas, o que limitou comparações. A eficácia dos classificadores esteve fortemente associada à maior quantidade de atributos nos testes.

Por fim, as regiões cerebrais mais associadas ao TDAH incluíram o giro frontal, o córtex orbitofrontal, o córtex cingulado, o cerebelo, o córtex motor e o lobo temporal.

### Conclusões

Esta revisão, com resultados ainda preliminares, mostrou que a combinação de rs-fMRI com aprendizado de máquina é uma abordagem promissora para auxiliar no diagnóstico do TDAH. O algoritmo SVM se destacou com os melhores desempenhos de acurácia, mas a aplicação em amostras pequenas gera riscos de overfitting. Além disso, a generalização dos modelos é um desafio, dificultada pela heterogeneidade metodológica entre os estudos, as amostras demográficas limitadas, com baixa participação de mulheres, e a falta de padronização diagnóstica. A baixa disponibilização de códigos, também, prejudica a reproduzibilidade dos trabalhos. Para que haja avanço na área, é necessário que exista maior transparência nos estudos, a padronização dos protocolos, a diversidade dos dados e a validação dos modelos em contextos clínicos reais.

### Bibliografia

- ❖ Miao, B., & Zhang, Y. (2017). A feature selection method for classification of ADHD. <https://doi.org/10.1109/iccss.2017.8091376>
- ❖ Balasubramanian, S., Karthikeyan, S., & Karthikeyan, M. (2023). Optimized machine learning model for identifying and predicting Attention Deficit Hyperactivity Disorder (ADHD). <https://doi.org/10.1109/icccnt56998.2023.10307486>
- ❖ Sen, B., Borle, N. C., Greiner, R., & Brown, M. R. G. (2018). A general prediction model for the detection of ADHD and Autism using structural and functional MRI. <https://doi.org/10.1371/journal.pone.0194856>
- ❖ Altun, S., Alkan, A., & Altun, H. (2022). Automatic Diagnosis of Attention Deficit Hyperactivity Disorder with Continuous Wavelet Transform and Convolutional Neural Network. <https://doi.org/10.9758/cpn.2022.20.4.715>