

Inteligência artificial na previsão de desfechos e planejamento neurocirúrgico

Artificial intelligence in outcome prediction and neurosurgical planning

Inteligencia artificial en la predicción de resultados y la planificación neuroquirúrgica

Wesley Lima Guimarães¹, Ana Paula Beirigo Barbosa², Gerley Adriano Miranda Cruz³, Marcus Kalyel Ferreira Godoi⁴, Maria Carolina Mota Mendes⁵, Salvador Rassi Filho⁶, Jalsi Tacon Arruda⁷

1.Discente, Curso de Medicina, Universidade Evangélica de Goiás (UniEVANGÉLICA). Anápolis-GO, Brasil. Orcid: <https://orcid.org/0009-0002-7457-4448>

2.Discente, Curso de Medicina, Universidade Evangélica de Goiás (UniEVANGÉLICA). Anápolis-GO, Brasil. Orcid: <https://orcid.org/0009-0005-2918-934X>

3.Discente, Curso de Medicina, Universidade Evangélica de Goiás (UniEVANGÉLICA). Anápolis-GO, Brasil. Orcid: <https://orcid.org/0009-0001-5303-8251>

4.Discente, Curso de Medicina, Universidade Evangélica de Goiás (UniEVANGÉLICA). Anápolis-GO, Brasil. Orcid: <https://orcid.org/0009-0003-2466-3052>

5.Discente, Curso de Medicina, Universidade Evangélica de Goiás (UniEVANGÉLICA). Anápolis-GO, Brasil. Orcid: <https://orcid.org/0009-0008-6889-7498>

6.Discente, Curso de Medicina, Universidade Evangélica de Goiás (UniEVANGÉLICA). Anápolis-GO, Brasil. Orcid: <https://orcid.org/0009-0001-2444-754X>

7.Docente, Doutora em Ciências da Saúde, Curso de Medicina, Universidade Evangélica de Goiás (UniEVANGÉLICA). Anápolis-GO, Brasil. Orcid: <https://orcid.org/0000-0001-7091-4850>

Resumo

Introdução. A metástase de tumores sólidos é comum em neurocirurgia e seu tratamento enfrenta desafios como a radioresistência e a dificuldade de acessar áreas centrais do cérebro. Tecnologias avançadas, especialmente com aprendizado de máquina, têm melhorado a precisão diagnóstica e preditiva na neurocirurgia, mas há lacunas na literatura sobre sua aplicação. **Objetivo.** A presente revisão tem por objetivo analisar o potencial das técnicas de *Machine Learning* (ML) nos processos neurocirúrgicos. **Método.** Foram coletados dados das bases de dados PubMed, Scopus e Web of Science, nos quais foram utilizados os descritores *Brain Neoplasm*, *Brain Tumor*, *Machine Learning* e *Neurosurgical Procedure*. **Resultados.** Modelos de ML recentes mostraram alta precisão na previsão de resposta terapêutica e progressão de metástases, superando métodos tradicionais, especialmente quando integrados a dados clínicos e radiômicos. Ferramentas automatizadas também têm avançado na segmentação de tumores, embora melhorias ainda sejam necessárias na detecção de pequenas lesões. O ML tem se destacado no monitoramento longitudinal, otimizando análises volumétricas e decisões clínicas. Na navegação cirúrgica, acelera a dissecação tumoral e aprimora a identificação de tumores, com grande potencial para personalizar tratamentos de forma precisa e individualizada. **Conclusão.** A exploração das aplicações de técnicas de ML na neurocirurgia, focando no tratamento de tumores cerebrais, revelou um panorama promissor sobre como o ML pode transformar o campo da neurociência, desde o planejamento até a execução de intervenções cirúrgicas.

Unitermos. Inteligência Artificial; Neurocirurgia; *Machine Learning*; Planejamento

Abstract

Introduction. The metastasis of solid tumors is common in neurosurgery, and its treatment faces challenges such as radioresistance and difficulty accessing central areas of the brain. Advanced technologies, especially those involving machine learning, have improved diagnostic and predictive accuracy in neurosurgery; however, gaps remain in the literature regarding their application. **Objective.** This review aims to analyze the potential of machine learning

(ML) techniques in neurosurgical processes. **Method.** Data were collected from the PubMed, Scopus, and Web of Science databases using the descriptors Brain Neoplasm, Brain Tumor, Machine Learning, and Neurosurgical Procedure. **Results.** Recent ML models demonstrated high accuracy in predicting therapeutic responses and metastasis progression, surpassing traditional methods, especially when integrated with clinical and radiomic data. Automated tools have also advanced tumor segmentation, though improvements are still needed for detecting small lesions. ML has stood out in longitudinal monitoring, optimizing volumetric analyses and clinical decision-making. In surgical navigation, accelerates tumor dissection and enhances tumor identification, showing great potential to personalize treatments accurately and individually. **Conclusion.** Exploring the applications of ML techniques in neurosurgery, focusing on brain tumor treatment, has revealed a promising outlook on how ML can transform the field of neuroscience, from planning to executing surgical interventions.

Keywords. Artificial Intelligence; Neurosurgery; Machine Learning; Planning

Resumen

Introducción. La metástasis de tumores sólidos es común en neurocirugía, y su tratamiento enfrenta desafíos como la radiorresistencia y la dificultad de acceder a áreas centrales del cerebro. Las tecnologías avanzadas, especialmente con el aprendizaje automático, han mejorado la precisión diagnóstica y predictiva en neurocirugía, pero existen lagunas en la literatura sobre su aplicación. **Objetivo.** La presente revisión tiene como objetivo analizar el potencial de las técnicas de *Machine Learning* (ML) en los procesos neuroquirúrgicos. **Método.** Se recopilaron datos de las bases de datos PubMed, Scopus y Web of Science, en las que se utilizaron los descriptores *Brain Neoplasm*, *Brain Tumor*, *Machine Learning* y *Neurosurgical Procedure*. **Resultados.** Los modelos recientes de ML mostraron una alta precisión en la predicción de la respuesta terapéutica y la progresión de metástasis, superando los métodos tradicionales, especialmente cuando se integran con datos clínicos y radiómicos. Las herramientas automatizadas también han avanzado en la segmentación de tumores, aunque aún se necesitan mejoras en la detección de lesiones pequeñas. El ML ha destacado en el monitoreo longitudinal, optimizando los análisis volumétricos y las decisiones clínicas. En la navegación quirúrgica, acelera la disección tumoral y mejora la identificación de tumores, con un gran potencial para personalizar los tratamientos de manera precisa e individualizada. **Conclusiones.** La exploración de las aplicaciones de técnicas de ML en la neurocirugía, enfocándose en el tratamiento de tumores cerebrales, reveló un panorama prometedor sobre cómo el ML puede transformar el campo de la neurociencia, desde la planificación hasta la ejecución de intervenciones quirúrgicas.

Palabras clave. Inteligencia Artificial; Neurocirugía; Machine Learning; Planificación quirúrgica

Trabalho realizado na Universidade Evangélica de Goiás. Anápolis-GO, Brasil.

Conflito de interesse: não

Recebido em: 22/11/2024

Aceito em: 12/03/2025

Endereço de correspondência: Jalsi Tacon Arruda. Universidade Evangélica de Goiás (UniEvangélica). Av. Universitária Km3,5. Cidade Universitária. Anápolis-GO, Brasil. CEP 75083-515. E-mail: jalsitacon@gmail.com

INTRODUÇÃO

A metástase de tumores sólidos são uma das formas de câncer mais prevalentes em pacientes com destino para neurocirurgia, seja pela diversidade de regiões que podem estar acometidas, ocorrendo nos pulmões, mamas ou cérebro, seja pelo crescente aparecimento na população devido a, sobretudo, as melhorias na manutenção

da saúde coletiva, criando uma sociedade com cidadãos cada vez mais idosos. Desta forma, é de extrema importância que os tratamentos neurocirúrgicos envolvendo tumores, em ênfase os malignos, possuam a efetividade necessária para garantir a sobrevivência do paciente e manter a qualidade de saúde¹.

Entretanto, é perceptível que os procedimentos cirúrgicos atuais de tumores malignos demonstram resultados insatisfatórios, como: dificuldade em promover cirurgias de tumores localizados em estruturas na parte central do cérebro; inefetividade da radioterapia no meio pós cirúrgico devido à radioresistência tumoral; possíveis danos à cérebros não completamente desenvolvidos e dificuldades em lidar com tumores generalizados e em estágios mais avançados².

Assim, para combater estes desafios, a medicina pesquisou e desenvolveu diversos novos métodos que possuem como o objetivo de garantir taxas de sucessos maiores e com mais regularidade, além de minimizar sequelas aos pacientes no meio pós-operatório a fim de garantir uma recuperação mais rápida e eficiente e de proporcionar uma localização mais precisa sobre a região do tumor e avaliar a melhor forma de procedimento, que visa o menor número de erros e possíveis sequelas ao paciente possível³.

Dessa forma, a evolução dos procedimentos neurocirúrgicos está intimamente ligada com a evolução tecnológica e sua aplicação na medicina. Avanços

tecnológicos na neurocirurgia permitem cirurgias mais precisas, avançadas e menos invasivas, melhorando as capacidades de diagnóstico, monitoramento e tratamento⁴. Avanços tecnológicos recentes na neurocirurgia, como o mapeamento pré-operatório e o planejamento de trajetória, aumentaram a segurança e a precisão cirúrgica na neuro-oncologia operatória⁵.

Na área de Inteligência Artificial, a técnica do aprendizado de máquina ou *Machine Learning* (ML) é o instrumento que permite a interpretação de informações, realizada por computadores. Dentro desta área, há métodos diferentes de manipular dados, o que permite uma avaliação mais eficiente de um tema, a depender dos critérios aplicados e dos objetivos requeridos. A grande vantagem desta técnica em relação à programação tradicional é a geração de um algoritmo que representa a relação desejada, sendo possível aplicar a ML em tarefas mais simples, como classificação, até tarefas mais complicadas, como uma análise preditiva^{6,7}.

No campo da neurocirurgia, seja no planejamento ou até mesmo na execução cirúrgica, tecnologias baseadas em técnicas provenientes de modelos de *Machine Learning* têm facilitado inúmeras tomadas de decisões, em especial, mediante ao uso de redes neurais artificiais⁸. Sob a perspectiva do tratamento de tumores cerebrais, tais abordagens permitem não somente a conclusão de um diagnóstico preciso, como também a previsão tanto da evolução tumoral quanto da própria sobrevivência do

paciente com base em parâmetros extrínsecos ao quadro oncológico^{9,10}. Apesar de já existirem outras rotinas estocásticas aplicáveis ao meio médico, estudos sugerem que modelos de ML preveem resultados após uma neurocirurgia com uma precisão média de 94,5% quando comparado a mecanismos de regressão logística, por exemplo¹¹. Em suma, essas estratégias configuram-se como grandes promessas em intervenções oncológicas de complexidade variável¹².

Para que sejam colocados em prática, de modo confiável, quaisquer métodos envolvendo as áreas de *Machine Learning* e de neurocirurgia, observa-se a importância de literaturas relevantes que possam abranger o tema. No entanto, há certas lacunas nas bibliografias, seja na falta de evidências ou no consenso da metodologia, configurando um entrave para o avanço da prática médica. Nesse cenário, surge a importância, por meio de uma revisão integrativa de literatura, de se investigar as possíveis aplicações de técnicas de *Machine Learning* no âmbito da neurocirurgia.

MÉTODO

Trata-se de uma revisão de literatura do tipo integrativa, isto é, uma abordagem científica com o intuito de combinar e sintetizar dados relevantes a partir de um número variado de fontes bibliográficas. Com base nessa premissa, a presente revisão segue um processo estruturado que inclui a formulação de um problema, busca, avaliação,

análise e interpretação dos dados e apresentação dos resultados. Essa organização permite a resolução da seguinte pergunta norteadora: Como as técnicas de *Machine Learning* têm sido aplicadas para melhorar os resultados em procedimentos neurocirúrgicos no tratamento de tumores cerebrais?

A construção da pergunta norteadora proposta anteriormente foi formada com base na estruturação da estratégia PICO (População, Intervenção e Contexto). A população de interesse limitou-se a pacientes com tumores cerebrais submetidos a procedimentos neurocirúrgicos. Quanto à intervenção, o estudo objetivou investigar a aplicação de técnicas de *Machine Learning* em diferentes etapas de procedimentos neurocirúrgicos. Em suma, o contexto em relevância direcionou-se aos procedimentos para o tratamento de tumores cerebrais.

Para a discussão do questionamento proposto na busca por artigos, cuja finalidade é a exposição da temática em evidência, foram utilizadas as bases de dados *National Library of Medicine* (MEDLINE PubMed), *Web of Science* e Scopus. Os descritores escolhidos foram *Machine Learning*, *Neurosurgical Procedure* e *Brain Neoplasm*. Tais termos foram obtidos mediante buscas realizadas nas plataformas Descritores em Ciências da Saúde (DeCS) e *Medical Subject Headings* (MeSH). Para ambos os acervos de literatura científica, a expressão de busca foi: ("*Brain Neoplasm**" OR "*Brain Tumor**") AND "*Machine Learning*" AND "*Neurosurgical Procedure**".

A expressão lógica foi construída com base nos elementos centrais da pergunta norteadora. Todavia, torna-se relevante salientar que foram aplicadas certas adaptações conforme as características de cada uma das bases escolhidas. Para o MEDLINE PubMed, os termos foram ajustados por meio da integração com a ferramenta MeSH, – essa abordagem permitiu uma maximização da produtividade de busca com a presente plataforma. Por outro lado, tanto no *Web of Science*, quanto no *Scopus*, não houve mudanças na expressão.

Os critérios de inclusão, além do atendimento ao questionamento norteador, foram: estudos publicados em revistas científicas indexadas nos últimos cinco anos, materiais escritos na língua inglesa e trabalhos com acesso ao material completo. Com a finalidade de melhorar a transparência e a elaboração da revisão integrativa, a diretriz *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* (PRISMA) serviu de protocolo para a divisão da seleção dos artigos em: identificação, triagem, elegibilidade e inclusão. Apesar de ser um conjunto de protocolos comumente observados em revisões sistemáticas e metanálises, mostrou-se conveniente o seu uso para a revisão integrativa proposta. O rastreio da literatura necessária para a composição da presente revisão corresponde ao dia 2 de outubro de 2024.

RESULTADOS

Em um primeiro momento, na etapa de identificação, com uso da expressão de busca supracitada, foram encontrados 123 estudos, sendo divididos em: *PubMed* (52), *Web of Science* (18) e *Scopus* (53). Em seguida, após processo de triagem, – estágio correspondente a uma leitura restrita ao título e resumo dos artigos –, com a aplicação dos critérios, reservou-se tais quantidades para a próxima fase: *PubMed* (32), *Web of Science* (11) e *Scopus* (41). Após a aplicação dos elementos relevantes para a avaliação dos artigos elegíveis, tendo como parâmetro discriminatório a concordância com a pergunta norteadora em evidência, 23 artigos foram escolhidos para o acervo final da presente revisão integrativa de literatura. A Figura 1 resume, de forma procedural, a execução das etapas concernentes à metodologia.

Para garantir a representatividade da amostra, estão apresentados todos os estudos encontrados considerando a questão norteadora. Dos 23 trabalhos selecionados, 13 foram escritos nos anos de 2023 e 2024, 8 entre 2021 e 2022 e dois entre 2019 e 2020, o que destaca se tratar de uma temática recente no âmbito científico. Considerando os tipos de estudos, 11 foram do tipo retrospectivos, quatro experimentais, dois experimentais e retrospectivos, dois retrospectivos e observacionais, e os demais se dividiram entre observacional e prospectivo, coorte retrospectivo e observacional prospectivo e retrospectivo sendo apenas um de cada. Os trabalhos selecionados foram divididos em uma

tabela e uma figura. A Figura 2 resume os principais focos e abordagens dos autores em seus trabalhos, enquanto a Tabela 1 elenca os principais dados relevantes dos artigos incluídos na presente revisão.

Figura 1. Fluxograma PRISMA.

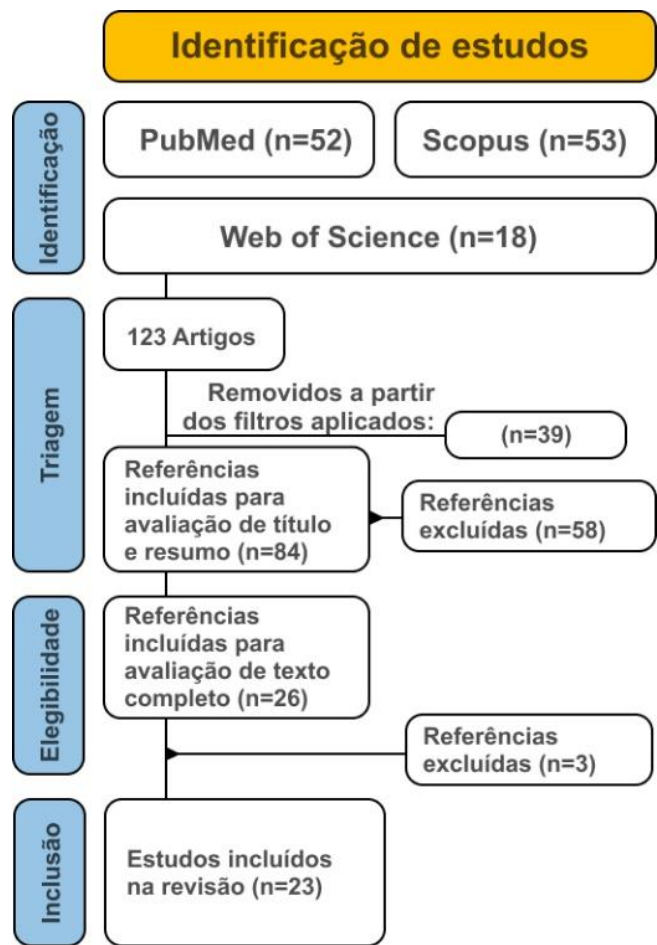


Figura 2. Categorização das principais abordagens de cada artigo selecionado.

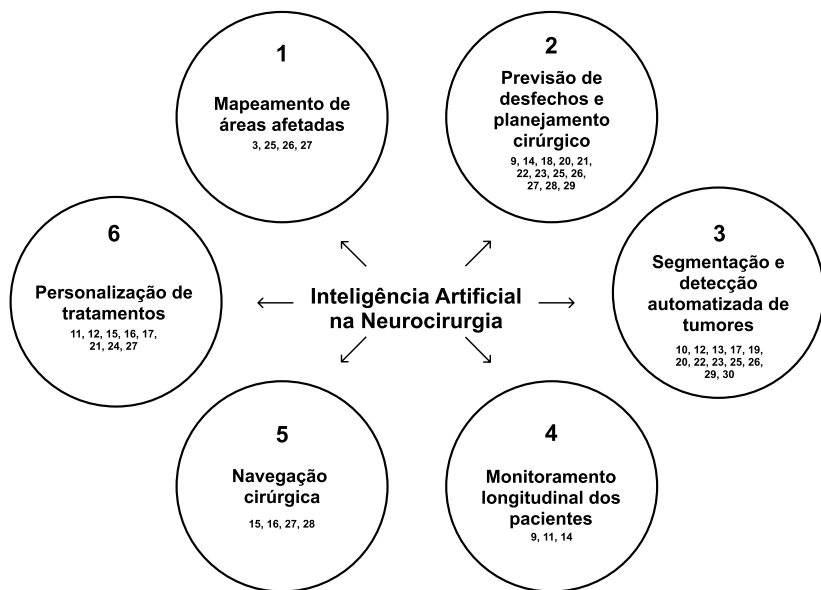


Tabela 1. Principais achados e dados relevantes.

| Autor Ano | Objetivo | Desenho do estudo | Categoria(s) |
|--|---|-------------------------------------|--------------|
| Zhao <i>et al.</i> 2024 ⁹ | Desenvolver um modelo de ML que possa prever os resultados de controle local da metástase cerebral após uma SRS | Estudo retrospectivo | 2, 4 |
| Lee <i>et al.</i> 2023 ¹⁰ | Avaliar a viabilidade de um esquema de segmentação de lesões intracranianas baseado em DL no contexto de aprendizado federado (FL). | Estudo retrospectivo | 3 |
| Cho <i>et al.</i> 2024 ¹¹ | Comparar as performances de três modelos de IA para identificar o número ideal de exames de MR, avaliando como a sequência numérica de escaneamentos afeta a acurácia de predição. | Estudo experimental e retrospectivo | 4, 6 |
| Jeong <i>et al.</i> 2023 ¹² | Avaliar se a detecção e quantificação de BMs feitas por DL podem sugerir opções de tratamento para estas neoplasias. | Estudo retrospectivo | 3, 6 |
| Hammer <i>et al.</i> 2024 ¹³ | O estudo procura avaliar se o SimU-Net, um programa de identificação e análise volumétrica de tumores, é capaz de avaliar os tumores nos períodos pré e pós os procedimentos. | Estudo retrospectivo observacional | 3 |
| Duet <i>et al.</i> 2023 ¹⁴ | Desenvolver e avaliar uma Pipeline de predição baseada em radiômica para identificar prospectivamente pacientes com BM que são insensíveis à terapia SRS, especialmente aqueles que estão em potencial risco de doença progressiva. | Estudo retrospectivo | 2, 4 |
| Devries <i>et al.</i> 2023 ¹⁵ | Examinar a variabilidade interobservadora da rotulagem da aparência qualitativa, comparar técnicas qualitativas e quantitativas e usar rótulos de aparência qualitativa para interpretar modelos radiômicos complexos. | Estudo Retrospectivo | |
| Shimamoto <i>et al.</i> 2023 ¹⁶ | Avaliar a viabilidade de um mapeamento de imagem que correlacione pMR's e iMR's com CNN's para compensar as mudanças cerebrais após a abertura dural. | Estudo retrospectivo observacional | 5, 6 |

Tabela 1 (cont.). Principais achados e dados relevantes.

| Autor Ano | Objetivo | Desenho do estudo | Categoria(s) |
|---|--|--|--------------|
| Wang <i>et al.</i> 2023 ¹⁷ | Avaliar o desempenho e o uso da ferramenta VBrain para detecção de tumores cerebrais, levando em consideração aspectos sociodemográficos e clínicos. | Estudo retrospectivo | 3, 6 |
| Devries <i>et al.</i> 2022 ¹⁸ | Investigar a precisão de modelos prognósticos que utilizam características clínicas e radiômicas para prever a progressão de BM tratadas com SRS, além de analisar o impacto do tipo de câncer primário, volume da BM e variação dos modelos de scanner de MR. | Estudo retrospectivo | 2 |
| Chao <i>et al.</i> 2022 ¹⁹ | Investigar a capacidade de IA e DL em segmentar possíveis áreas afetadas por tumores e Acidentes vasculares encefálicos, eliminando a participação humana no processo, para utilização em sistemas de planejamento de tratamento (TPS). | Experimental retrospectivo | 3 |
| Yang <i>et al.</i> 2022 ²⁰ | O estudo se concentra no desenvolvimento de uma plataforma automatizada de segmentação de metástases cerebrais para auxiliar no planejamento de radiocirurgia estereotáxica. | Pesquisa Experimental | 2, 3 |
| Jaberipour <i>et al.</i> 2021 ²¹ | O estudo busca prever falhas locais em tratamentos de SRS em pacientes com gliomas cerebrais. Através de técnicas de aprendizado de máquina, o objetivo é identificar previamente os pacientes com maior risco de falha no tratamento, otimizando intervenções terapêuticas. | Estudo observacional e prospectivo | 2, 6 |
| Fang <i>et al.</i> 2021 ²² | O estudo busca modelos de Machine Learning (ML) que ajudem na identificação e tratamento de NFPA em pacientes no meio pós cirúrgico. | Retrospectivo Experimental | 4, 6 |
| Zhou <i>et al.</i> 2020 ²³ | O estudo tem como objetivo desenvolver e investigar métodos de DL para a detecção de BM usando ressonância magnética ponderada em T1, com foco em auxiliar o planejamento de SRS. | Estudo retrospectivo | 2, 3 |
| Boaro <i>et al.</i> 2024 ³ | Desenvolver e avaliar abordagens de ML para a identificação muscular usando MEPs intraoperatórios, comparando seu desempenho com especialistas humanos. | Estudo retrospectivo | 1 |
| Zhu <i>et al.</i> 2023 ²⁴ | Determinar qual abordagem cirúrgica proporciona melhores resultados individuais e identificar variáveis relevantes para a heterogeneidade de respostas ao tratamento. | Coorte retrospectivo | 6 |
| Redha <i>et al.</i> 2023 ²⁵ | O artigo propõe um método com IA usando LSGAN para gerar imagens de RM com diferentes contrastes (mpMRI), ajudando a identificar tumores com mais precisão e detalhes, o que facilita o planejamento cirúrgico. | Prospectivo experimental | 1, 3 |
| Cardone <i>et al.</i> 2023 ²⁶ | Desenvolver modelos baseados em ML, utilizando características obtidas de imagens térmicas infravermelhas (IR), para permitir uma alta precisão da delimitação de áreas tumorais (aumento da precisão dos limites dos tumores) durante a neurocirurgia. | Estudo experimental | 1, 2, 3 |
| Doyen <i>et al.</i> 2021 ²⁷ | O estudo propõe um parcelamento cerebral baseado em conectividade estrutural, adaptável a cérebros normais e distorcidos anatomicamente, visando maior precisão cirúrgica em pacientes com tumores cerebrais. | Estudo observacional com análise retrospectiva e prospectiva | 1, 2, 5, 6 |
| Fabelo <i>et al.</i> 2019 ²⁸ | Desenvolver um sistema de visualização auxiliar baseado em DL para a identificação in vivo de tumores GBM durante cirurgias, utilizando imagens hiperespectrais do tecido cerebral humano. | Estudo experimental | 2, 5 |
| Tariciotti <i>et al.</i> 2022 ²⁹ | Desenvolver e validar um modelo de DL para diferenciar glioblastomas, metástases cerebrais e linfoma primário do sistema nervoso central (PCNSL) em imagens pré-operatórias de ressonância magnética com contraste. | Retrospectivo | 2, 3 |
| Bouget <i>et al.</i> 2021 ³⁰ | Melhorar a segmentação automática de tumores em pacientes com glioblastoma presumido e comparar os resultados com a segmentação manual. | Pesquisa Experimental | 3 |

Dessa forma, modelos desenvolvidos demonstraram alta precisão na previsão da resposta terapêutica e progressão de metástases, superando métodos tradicionais de avaliação tanto em acurácia quanto na necessidade de exames complementares^{9,11}, além de melhorias quando integrados a dados clínicos e radiômicos promovendo uma maior capacidade de identificar a sensibilidade de tumores a certos tipos de terapia e melhorias significativas na precisão durante a cirurgia^{14,15}. Em termos de segmentação automatizada, ferramentas foram desenvolvidas e validadas para identificar metástases em diversas fases do desenvolvimento tumoral^{10,17}, embora estudos apontem que a detecção de pequenas lesões ainda precisa de avanços, pois são mais complexas e laboriosas para extração dados^{20,23}.


No monitoramento longitudinal de pacientes, estudos destacaram o uso de IA para análises volumétricas e sugestão de tratamentos alinhados às decisões clínicas^{12,13}. Análises de outros estudos apontaram que a delimitação e localização de tumores foi associada à subjetividade e que a IA pode melhorar essa análise¹⁹, enquanto avanços em relação a identificação do estudo do tumor, a eficácia do tratamento cirúrgico e a resposta em relação aos tratamentos terapêuticos, possibilitaram uma diminuição significativa de tempo humano na averiguação dessas etapas¹³.

Em navegação cirúrgica, IA pode ser combinada com ressonância pré e intraoperatória para acelerar a dissecação

do tumor¹⁶ ou incorporados em sistemas de identificação de tumores durante o processo operatório²⁸. Por fim, estudos também destacaram a IA na personalização de tratamentos, ajustando intervenções de forma precisa e individualizada para cada paciente, levando em consideração características clínicas, sociais e outros aspectos^{18,24}.

Ao analisar as metodologias propostas pelos autores, constatou-se uma diferença significativa nas abordagens para análise de imagens de ressonância magnética (RM), detecção de tumores e geração de relatórios. As metodologias analisadas foram: Segmentação automatizada utilizando CNN's e AGU-Net (Glioblastoma Surgery), TDBL+REC e FDBL. A Figura 3 apresenta uma comparação entre as metodologias descritas.

Figura 3. Comparação entre tempo de processamento de segmentação entre os modelos utilizados.



DISCUSSÃO

A análise desta revisão integrativa reafirma que as técnicas de inteligência artificial (IA) e, em particular, o *Machine Learning* (ML), apesar de serem recentes têm sido de grande importância e tiveram um impacto significativo na neurocirurgia, em que a IA integrada a dados clínicos e radiômicos, resultaram em um diagnóstico otimizado, prognóstico e terapêutica personalizada mais precisa de tumores cerebrais quando comparada com as abordagens tradicionais^{9,11}. Outros modelos propostos comprovaram a utilidade da IA na avaliação de evolução tumoral e no facilitamento da monitoração de respostas ao tratamento e intervenções subsequentes¹³. Esses avanços representam uma melhoria em fatores críticos para procedimentos de oncologia complexos, tais como um aumento significativo na precisão do procedimento, precisão da previsão de resposta ao tratamento e segmentação automatizada do tumor.

Entre as vantagens mais significativas da IA, pode-se mencionar a capacidade de processar enormes quantidades de dados médicos e hospitalares para recomendação em tempo real, fato que supera uma abordagem convencional feita apenas pelo profissional médico. Os sistemas que fazem uso da tecnologia em questão têm mostrado eficiência ao serem combinados com técnicas de imagem intraoperatória, facilitando a dissecação do tumor e diminuindo o risco de danos ao tecido cerebral saudável¹⁶. Ferramentas como as redes neurais convolucionais (CNN's), que já são utilizados por sistemas de navegação cirúrgica, permitem aos

neurocirurgias identificarem as margens do tumor e realizar a remoção minimamente invasiva com mais segurança. Tais fatos não apenas aumentam a taxa de sucesso dos procedimentos como também reduzem os riscos de sequelas pós-operatórias, representando um avanço substancial na neurocirurgia oncológica.

No entanto, como qualquer tecnologia emergente, a IA na neurocirurgia enfrenta desafios que precisam de maiores testes e pesquisas. Estudos apontam que ferramentas de IA ainda tem dificuldades para identificar tumores muito pequenos ou em estágios iniciais, o que compromete a capacidade de detecção precoce, um aspecto crítico para o sucesso terapêutico^{10,17,20,23}. Outro desafio vem da diversidade das fontes de dados existentes e da dificuldade em unificar essas informações de maneira consistente e padronizada entre instituições diferentes. Por exemplo, enquanto o Aprendizado Federado busca integrar dados de diversas instituições para aumentar a confiabilidade dos modelos, essa abordagem esbarra em problemas logísticos e estruturais que limitam a adoção em larga escala¹⁰.

Esses obstáculos não devem ser vistos como barreiras intransponíveis, mas sim como lembretes da complexidade da integração entre tecnologia e saúde. Para que os sistemas de IA se consolidem na prática clínica diária, é preciso não apenas desenvolver algoritmos mais robustos, mas também garantir que as instituições de saúde contem com a infraestrutura necessária para essa transição. Além disso, a adoção de IA em neurocirurgia levanta questões éticas

importantes relacionadas a privacidade de dados, responsabilidade e segurança do paciente e exigem regulamentações cuidadosas para garantir que o uso dessas tecnologias seja seguro e ético. O potencial de decisões baseadas em IA afetar diretamente a saúde dos pacientes ressalta a necessidade de um monitoramento contínuo por profissionais capacitados, ou seja, não há como essas tecnologias substituam o papel do médico, mas otimizá-lo^{21,24}.

CONCLUSÃO

A exploração das aplicações de técnicas de Machine Learning (ML) na neurocirurgia, focando no tratamento de tumores cerebrais, revelou um panorama promissor sobre como o ML pode transformar o campo da neurociência, desde o planejamento até a execução de intervenções cirúrgicas. Foi demonstrado que modelos de ML não apenas melhoram a precisão nas previsões de desfechos cirúrgicos, mas também contribuem para a personalização do tratamento, otimizando a tomada de decisões clínicas.

Os avanços em segmentação automatizada, previsão de resposta terapêutica e monitoramento longitudinal destacam a capacidade do ML em lidar com as amplas complexidades dos tumores cerebrais, superando limitações dos métodos tradicionais. A integração de dados clínicos e radiômicos com algoritmos de ML se mostrou eficaz, promovendo uma abordagem mais holística no tratamento dos pacientes.

Entretanto, há lacunas na literatura, como a necessidade de estudos multicêntricos e validações externas que possam corroborar para a eficácia e a generalização dos modelos. Além disso, a variabilidade nas metodologias e a falta de consenso em algumas abordagens indicam que ainda há necessidade de melhorias e padronizações nas pesquisas.

Portanto, a implementação de técnicas de ML na neurocirurgia representa uma inovação que pode revolucionar o tratamento de tumores cerebrais, mas requer um esforço contínuo para superar os entraves existentes. Futuros estudos devem se concentrar em validar as descobertas atuais e explorar novas aplicações do ML, garantindo melhores resultados clínicos e qualidade de vida para os pacientes.

REFERÊNCIAS

- 1.Thon N, Karschnia P, Baumgarten LV, Niyazi M, Steinbach JP, Tonn JC. Neurosurgical interventions for cerebral metastases of solid tumors. *Dtsch Arztebl Int* 2023;120:162-9. <https://doi.org/10.3238/arztebl.m2022.0410>
- 2.Galicich J. Surgery of malignant brain tumors. *Semin Neurol* 1981;1:159-68. <https://doi.org/10.1055/s-2008-1063894>
- 3.Boaro A, Azzari A, Basaldella F, Nunes S, Feletti A, Bicego M, *et al*. Machine learning allows expert level classification of intraoperative motor evoked potentials during neurosurgical procedures. *Comput Biol Med* 2024;180:109032. <https://doi.org/10.1016/j.combiomed.2024.109032>
- 4.Rezai AR. The Evolution of Technology and Neurosurgery. *Neurosurgery* 2014;61:66-8. <https://doi.org/10.1227/neu.0000000000000419>
- 5.Rennert RC, Santiago-Dieppa DR, Figueroa J, Sanai N, Carter BS. Future directions of operative neuro-oncology. *J Neuro Oncol* 2016;130:377-82. <https://doi.org/10.1007/s11060-016-2180-3>
- 6.Deo RC. Machine Learning in Medicine. *Circulation* 2015;132:1920-30. <https://doi.org/10.1161/circulationaha.115.001593>
- 7.Choi RY, Coyner AS, Kalpathy-Cramer J, Chiang MF, Campbell JP. Introduction to Machine Learning, Neural Networks, and Deep

- Learning. Transl Vis Sci Technol 2020;9:14. <https://doi.org/10.1167/tvst.9.2.14>
- 8.Buchlak QD, Esmaili N, Leveque JC, Farrokhi F, Bennett C, Piccardi M, *et al.* Machine learning applications to clinical decision support in neurosurgery: an artificial intelligence augmented systematic review. Neurosurgical Ver 2019;43:1235-53. <https://doi.org/10.1007/s10143-019-01163-8>
- 9.Zhao J, Vaio E, Wang Y, Yang Z, Cui Y, Reitman ZJ, *et al.* Dose-Incorporated deep ensemble learning for improving brain metastasis SRS outcome prediction. Int J Radiat Oncol Biol Phys 2024;120:603-13. <https://doi.org/10.1016/j.ijrobp.2024.04.006>
- 10.Lee W, Hong J, Lin Y, Lu Y, Hsu Y, Lee C, *et al.* Federated learning: a cross-institutional feasibility study of deep learning based intracranial tumor delineation framework for stereotactic radiosurgery. J Magn Reson Imaging 2023;59:1967-75. <https://doi.org/10.1002/jmri.28950>
- 11.Cho SJ, Cho W, Choi D, Sim G, Jeong SY, Baik SH, *et al.* Prediction of treatment response after stereotactic radiosurgery of brain metastasis using deep learning and radiomics on longitudinal MRI data. Sci Rep 2024;14:11085. <https://doi.org/10.1038/s41598-024-60781-5>
- 12.Jeong H, Park JE, Kim N, Yoon SK, Kim HS. Deep learning-based detection and quantification of brain metastases on black-blood imaging can provide treatment suggestions: a clinical cohort study. Eur Radiol 2023;34:2062-71. <https://doi.org/10.1007/s00330-023-10120-5>
- 13.Hammer Y, Najjar W, Kahanov L, Joskowicz L, Shoshan Y. Two is better than one: longitudinal detection and volumetric evaluation of brain metastases after Stereotactic Radiosurgery with a deep learning pipeline. J Neuro Oncol 2024;166:547-55. <https://doi.org/10.1007/s11060-024-04580-y>
- 14.Du P, Liu X, Xiang R, Lv K, Chen H, Liu W, *et al.* Development and validation of a radiomics-based prediction pipeline for the response to stereotactic radiosurgery therapy in brain metastases. Eur Radiol 2023;33:8925-35. <https://doi.org/10.1007/s00330-023-09930-4>
- 15.DeVries DA, Tang T, Albweady A, Leung A, Laba J, Johnson C, *et al.* Predicting stereotactic radiosurgery outcomes with multi-observer qualitative appearance labelling versus MRI radiomics. Sci Rep 2023;13:20977. <https://doi.org/10.1038/s41598-023-47702-8>
- 16.Shimamoto T, Sano Y, Yoshimitsu K, Masamune K, Muragaki Y. Precise brain-shift prediction by new combination of w-net deep learning for neurosurgical navigation. Neurol Med Chir 2023;63:295-303. <https://doi.org/10.2176/jns-nmc.2022-0350>
- 17.Wang JY, Qu V, Hui C, Sandhu N, Mendoza MG, Panjwani N, *et al.* Stratified assessment of an FDA-cleared deep learning algorithm for automated detection and contouring of metastatic brain tumors in stereotactic radiosurgery. Radiat Oncol 2023;18:61. <https://doi.org/10.1186/s13014-023-02246-z>

- 18.DeVries DA, Lagerwaard F, Zindler J, Yeung TP, Rodrigues G, Hajdok G, *et al.* Performance sensitivity analysis of brain metastasis stereotactic radiosurgery outcome prediction using MRI radiomics. *Sci Rep* 2022;12:20975. <https://doi.org/10.1038/s41598-022-25389-7>
- 19.Chao PJ, Chang L, Kang CL, Lin CH, Shieh CS, Wu JM, *et al.* Using deep learning models to analyze the cerebral edema complication caused by radiotherapy in patients with intracranial tumor. *Sci Rep* 2022;12:1555. <https://doi.org/10.1038/s41598-022-05455-w>
- 20.Yang Z, Chen M, Kazemimoghadam M, Ma L, Stojadinovic S, Timmerman R, *et al.* Deep-learning and radiomics ensemble classifier for false positive reduction in brain metastases segmentation. *Phys Med Amp Biol* 2022;67:025004. <https://doi.org/10.1088/1361-6560/ac4667>
- 21.Jaberipour M, Soliman H, Sahgal A, Sadeghi-Naini A. A priori prediction of local failure in brain metastasis after hypo-fractionated stereotactic radiotherapy using quantitative MRI and machine learning. *Sci Rep* 2021;11:21620. <https://doi.org/10.1038/s41598-021-01024-9>
- 22.Fang Y, Wang H, Feng M, Zhang W, Cao L, Ding C, *et al.* Machine-Learning prediction of postoperative pituitary hormonal outcomes in nonfunctioning pituitary adenomas: a multicenter study. *Front Endocrinol* 2021;12:748725. <https://doi.org/10.3389/fendo.2021.748725>
- 23.Zhou Z, Sanders JW, Johnson JM, Gule-Monroe MK, Chen MM, Briere TM, *et al.* Computer-aided detection of brain metastases in t1-weighted MRI for stereotactic radiosurgery using deep learning single-shot detectors. *Radiology* 2020;295:407-15. <https://doi.org/10.1148/radiol.2020191479>
- 24.Zhu E, Shi W, Chen Z, Wang J, Ai P, Wang X, *et al.* Reasoning and causal inference regarding surgical options for patients with low-grade gliomas using machine learning: A SEER-based study. *Cancer Med* 2023;12:20878-91. <https://doi.org/10.1002/cam4.6666>
- 25.Touati R, Kadoury S. A least square generative network based on invariant contrastive feature pair learning for multimodal MR image synthesis. *Int J Comput Assist Radiol Surg* 2023;18:971-9. <https://doi.org/10.1007/s11548-023-02916-z>
- 26.Cardone D, Trevisi G, Perpetuini D, Filippini C, Merla A, Mangiola A. Intraoperative thermal infrared imaging in neurosurgery: machine learning approaches for advanced segmentation of tumors. *Phys Eng Sci Med* 2023;46:325-37. <https://doi.org/10.1007/s13246-023-01222-x>
- 27.Doyen S, Nicholas P, Poologaindran A, Crawford L, Young IM, Romero-Garcia R, *et al.* Connectivity-based parcellation of normal and anatomically distorted human cerebral cortex. *Hum Brain Mapp* 2021;43:1358-69. <https://doi.org/10.1002/hbm.25728>
- 28.Fabelo H, Halicek M, Ortega S, Shahedi M, Szolna A, Piñeiro J, *et al.* Deep learning-based framework for in vivo identification of glioblastoma tumor using hyperspectral images of human brain. *Sensors* 2019;19:920. <https://doi.org/10.3390/s19040920>

29. Tariciotti L, Caccavella VM, Fiore G, Schisano L, Carrabba G, Borsa S, *et al.* A deep learning model for preoperative differentiation of glioblastoma, brain metastasis and primary central nervous system lymphoma: a pilot study. *Front Oncol* 2022;12:816638. <https://doi.org/10.3389/fonc.2022.816638>
30. Bouget D, Eijgelaar RS, Pedersen A, Kommers I, Ardon H, Barkhof F, *et al.* Glioblastoma surgery imaging-reporting and data system: validation and performance of the automated segmentation task. *Cancers* 2021;13:4674. <https://doi.org/10.3390/cancers13184674>