

Aplicações da inteligência artificial na ressonância magnética para diagnóstico de gliomas: Avanços, técnicas e limitações

Applications of artificial intelligence in magnetic resonance imaging for glioma diagnosis:
Advances, techniques, and limitations

Aplicaciones de la inteligencia artificial en la resonancia magnética para el diagnóstico de gliomas:
Avances, técnicas y limitaciones

Recebido: 17/11/2025 | Revisado: 29/01/2026 | Aceitado: 30/01/2026 | Publicado: 31/01/2026

Aynoã Souza Nascimento Sena

ORCID: <https://orcid.org/0009-0003-4971-2148>
Centro Universitário FMABC, Brasil
E-mail: Aynoasena71@gmail.com

Gabrielle Estevam Fernandes Pereira

ORCID: <https://orcid.org/0009-0001-0517-3504>
Centro Universitário FMABC, Brasil
E-mail:gabiestevam60duck@gmail.com

Emerson Barbosa da Silva

ORCID: <https://orcid.org/0000-0003-0953-479X>
Centro Universitário FMABC, Brasil
E-mail: emerson.silva@fmabc.net

Resumo

Introdução: A Ressonância Magnética (RM) é uma das principais técnicas utilizadas no diagnóstico de gliomas, mas apresenta limitações na diferenciação tumoral e na previsão de marcadores moleculares. A inteligência artificial (IA) tem se destacado como ferramenta complementar, capaz de aumentar a acurácia diagnóstica e apoiar decisões clínicas.

Método: Realizou-se uma revisão sistemática de artigos publicados entre 2015 e 2025 nas bases PubMed, MEDLINE e SciELO. A qualidade metodológica foi avaliada pela ferramenta AMSTAR-2.

Resultados: Os modelos baseados em DL e ML apresentaram desempenho promissor, com acurácia superior a 95% em alguns casos, especialmente nas redes neurais convolucionais (CNNs) e nos modelos híbridos que integram dados radiométricos e clínico-moleculares, apresentaram melhor sensibilidade e especificidade na diferenciação entre gliomas de baixo e alto grau. Entretanto, limitações como heterogeneidade metodológica, ausência de padronização dos protocolos de imagem, risco de overfitting e falta de validação externa robusta ainda restringem a aplicação clínica em larga escala.

Discussão: A IA mostrou-se promissora para automatizar análises complexas de imagem, reduzir viéses subjetivos e oferecer maior precisão diagnóstica. Contudo, desafios persistem quanto à padronização dos protocolos, a dificuldade de compatibilidade entre os sistemas e transparência dos algoritmos, são fatores que dificultam a sua incorporação clínica.

Conclusão: A integração da IA na RM representa um marco da neuroimagem oncológica, com um grande potencial revolucionário no diagnóstico de gliomas. Para incluir essas técnicas na prática clínica de forma segura são necessários estudos multicêntricos, modelos interpretáveis e políticas que assegurem a validação ética, reproduzibilidade e acessibilidade igualitária.

Palavras-chave: Espectroscopia de Ressonância Magnética; Glioma; Inteligência Artificial.

Abstract

Introduction: Magnetic resonance imaging (MRI) is one of the main techniques used in the diagnosis of gliomas, but it has limitations in tumor differentiation and in predicting molecular markers. Artificial intelligence (AI) has emerged as a complementary tool, capable of increasing diagnostic accuracy and supporting clinical decisions.

Method: A systematic review of articles published between 2015 and 2025 in the PubMed, MEDLINE, and SciELO databases was conducted. Methodological quality was assessed using the AMSTAR-2 tool.

Results: DL and ML-based models showed promising performance, with accuracy exceeding 95% in some cases, especially convolutional neural networks (CNNs). Hybrid models integrating radiomic and clinical-molecular data showed better sensitivity and specificity in differentiating between low- and high-grade gliomas. However, limitations such as methodological heterogeneity, lack of standardization of imaging protocols, risk of overfitting, and lack of robust external validation still restrict large-scale clinical application.

Discussion: AI has shown promise in automating complex image analyses, reducing subjective biases, and offering greater diagnostic accuracy. However, challenges persist regarding the standardization of protocols, the difficulty of compatibility between systems, and the transparency of algorithms, which are factors that hinder its clinical incorporation.

Conclusion: The integration of AI in MRI represents a milestone in oncological

neuroimaging, with great revolutionary potential in the diagnosis of gliomas. To safely include these techniques in clinical practice, multicenter studies, interpretable models, and policies that ensure ethical validation, reproducibility, and equitable accessibility are necessary.

Keywords: Magnetic Resonance Spectroscopy; Glioma; Artificial Intelligence.

Resumen

Introducción: La resonancia magnética (RM) es una de las principales técnicas utilizadas en el diagnóstico de gliomas, pero presenta limitaciones en la diferenciación tumoral y en la predicción de marcadores moleculares. La inteligencia artificial (IA) ha emergido como una herramienta complementaria, capaz de aumentar la precisión diagnóstica y apoyar las decisiones clínicas. **Método:** Se realizó una revisión sistemática de artículos publicados entre 2015 y 2025 en las bases de datos PubMed, MEDLINE y SciELO. La calidad metodológica se evaluó utilizando la herramienta AMSTAR-2. **Resultados:** Los modelos basados en DL y ML mostraron un rendimiento prometedor, con una precisión superior al 95% en algunos casos, especialmente las redes neuronales convolucionales (CNN). Los modelos híbridos que integran datos radiómicos y clínico-moleculares mostraron una mejor sensibilidad y especificidad para diferenciar entre gliomas de bajo y alto grado. Sin embargo, limitaciones como la heterogeneidad metodológica, la falta de estandarización de los protocolos de imagen, el riesgo de sobreajuste y la falta de una validación externa robusta aún restringen la aplicación clínica a gran escala. **Discusión:** La IA ha demostrado ser prometedora en la automatización de análisis de imágenes complejos, la reducción de sesgos subjetivos y la mejora de la precisión diagnóstica. Sin embargo, persisten desafíos en cuanto a la estandarización de protocolos, la dificultad de compatibilidad entre sistemas y la transparencia de los algoritmos, factores que dificultan su incorporación clínica. **Conclusión:** La integración de la IA en la resonancia magnética representa un hito en la neuroimagen oncológica, con un gran potencial revolucionario en el diagnóstico de gliomas. Para incorporar estas técnicas de forma segura en la práctica clínica, se requieren estudios multicéntricos, modelos interpretables y políticas que garanticen la validación ética, la reproducibilidad y la accesibilidad equitativa.

Palabras clave: Espectroscopía de Resonancia Magnética; Glioma; Inteligencia Artificial.

1. Introdução

Gliomas são tumores raros infiltrativos, constituem os tumores primários mais prevalentes do sistema nervoso central (SNC) em seres humanos, correspondendo a aproximadamente 40%–50% de todas as neoplasias intracranianas primárias e cerca de 81% dos tumores cerebrais malignos. De acordo com a Diretrizes de Tumor Cerebral no Adulto da CONITEC, os tumores gliais são neoplasias raras, correspondendo a cerca de 2% de todos os cânceres do Brasil, apesar de sua incidência relativamente baixa na população geral, essas lesões estão associadas a altos índices de morbidade e mortalidade, sendo o glioblastoma a variante histológica mais frequente, representando cerca de 45% dos casos. Essa forma apresenta um prognóstico particularmente desfavorável, com sobrevida relativa em cinco anos estimada em apenas 5% (Ostrom et al., 2014; Saúde, n.d.; Song et al., 2010). Os gliomas se originam das células da glia, tendo como responsabilidade nutrir e proteger os neurônios do Sistema Nervoso Central (SNC). Os gliomas apresentam diferentes subtipos, sendo o mais comum os derivados dos astrócitos denominado astrocitoma, porém não o mais agressivo. Esses tumores variam em graus de agressividade, sendo o glioblastoma o mais agressivo e letal classificado como grau IV de acordo com a Organização Mundial da Saúde (OMS) (Saúde, n.d.) Pela sua alta capacidade infiltrativa e mortalidade é possível explicar as dificuldades e limitações nos diagnósticos até os dias de hoje (Dra Suzana Maria Fleury Malheiros Co-orientador & José da Rocha, 2005). A OMS classifica os gliomas em quatro graus: sendo o de baixo grau (I e II) e alto grau (III e IV), sendo o glioblastoma (grau IV) o mais agressivo. Na contemporaneidade as classificações segundo a OMS incluem critérios moleculares (Saúde, n.d.).

Embora o diagnóstico definitivo exija confirmação histopatológica, diretrizes nacionais recomendam que a avaliação inicial inclua exames de neuroimagem como tomografia computadorizada (TC), que permite a identificação de massas expansivas e a exclusão de hemorragias intracranianas. Uma vez detectada a presença de uma lesão, solicita-se a realização de uma ressonância magnética (RM) convencional com contraste, exame que fornece informações detalhadas sobre o volume tumoral, o desvio das estruturas da linha média, a compressão de tecidos adjacentes e a presença de edema peritumoral. Além disso, a RM é fundamental no planejamento do tratamento inicial, geralmente a ressecção cirúrgica (debulking). Com base nas imagens obtidas, o neurocirurgião pode avaliar a delimitação da área afetada, o grau de agressividade do tumor e o risco potencial

de toxicidade em regiões funcionais próximas, o que contribui para uma abordagem mais segura e eficaz (Shukla et al., 2017). Como citado, a RM convencional é solicitada no início da descoberta da doença. Apesar dos avanços significativos, ainda se faz presente limitações relevantes a complexidade biológica e heterogeneidade entre os diferentes subtipos de glioma, especialmente no que diz respeito à previsão de características moleculares e genômicas, nesse contexto, a classificação proposta pela Organização Mundial da Saúde (OMS) em 2016 passou a integrar marcadores moleculares essenciais ao diagnóstico, complementando os critérios histopatológicos tradicionais. Destacam-se, entre esses marcadores, as mutações no gene da isocitrato desidrogenase (IDH) e a codeleção dos braços cromossômicos 1p/19q, parâmetros fundamentais para a estratificação clínica e prognóstica desses tumores. Estudos demonstram que a presença de mutações em IDH está associada a um curso clínico mais indolente e a maior resposta à quimioterapia, enquanto a codeleção 1p/19q correlaciona-se com desfechos mais favoráveis e sobrevida prolongada (Bonm et al., 2020; Tomás & Pojo, 2025). Além desses obstáculos técnicos e clínicos, também permanecem em evidência desafios relacionados à segurança da informação, à proteção da privacidade dos dados dos pacientes, à validação e confiabilidade dos algoritmos, aspectos regulatórios, éticos e legais, que devem ser cuidadosamente avaliados para a integração segura e eficaz da IA na prática médica (Xu et al., 2022).

Apesar dos avanços na neuroimagem e na caracterização molecular, persistem desafios significativos. A heterogeneidade biológica entre os subtipos de glioma dificulta a previsão precisa de características genômicas e moleculares apenas com base em imagens convencionais. Nesse cenário, a inteligência artificial (IA) emerge como uma ferramenta estratégica capaz de processar grandes quantidades de dados extraídos RM e identificar informações relevantes para o direcionamento terapêutico e reduz notoriamente a sobrecarga dos profissionais de saúde envolvidos nesses casos. Desde os primeiros conceitos propostos por Alan Turing (1950) e formalizados por John McCarthy como “a ciência e engenharia de máquinas inteligentes”, a IA evoluiu para um campo dinâmico capaz de aprender com grandes volumes de dados, aprimorar continuamente seu desempenho e apoiar decisões clínicas sem intervenção humana direta. A RM, por ser uma técnica não invasiva, tem se consolidado como método padrão na avaliação de gliomas. Diferentes sequências na RM oferecem dados estruturais, funcionais e metabólicos fundamentais para compreender a biologia tumoral. Com o apoio da inteligência artificial, esses dados podem ser analisados de forma mais precisa e personalizada. Na neuro-oncologia, algoritmos de aprendizado de máquina (ML) — como Random Forest (RF) e máquinas de vetores de suporte (SVM) — têm sido aplicados para identificar fatores prognósticos, refinar diagnósticos e prever respostas terapêuticas com base em perfis genéticos. O aprendizado profundo (Deep learning, DL), por sua vez, supera limitações do ML tradicional ao automatizar a extração de padrões complexos em grandes conjuntos de imagens. Associado à radiômica (que converte imagens médicas em dados quantitativos), o DL permite inferir características moleculares não invasivamente, auxiliar no prognóstico e orientar terapias personalizadas. Contudo, sua integração na prática médica enfrenta obstáculos técnicos, éticos e regulatórios, incluindo a necessidade de validação robusta dos algoritmos, garantia da privacidade dos dados dos pacientes, transparência nos processos decisórios e conformidade com normas legais e éticas. (Luo et al., 2023; Mehmadoost et al., 2024; Xu et al., 2022).

Diante desse contexto, o objetivo do artigo é analisar o uso de técnicas de machine learning (ML), deep learning (DL) e radiômica aplicadas à RM para diagnóstico e prognóstico de gliomas, destacando potencialidades e limitações metodológicas.

2. Metodologia

Realizou-se uma investigação documental de fonte indireta em artigos da literatura (Snyder, 2019), num estudo de natureza quantitativa em relação à quantidade de 9 (Nove) artigos selecionados para compor o “corpus” desta pesquisa é, de natureza qualitativa em relação às discussões realizadas sobre os artigos selecionados (Soares et al., n.d.) num estudo de revisão sistemática integrativa (Editorial revisão integrativa de pesquisa na enfermagem o rigor científico que lhe é exigido, n.d.).

O presente estudo foi delineado como uma revisão sistemática da literatura, conduzida de acordo com as

recomendações do protocolo PRISMA (Preferred Reporting Items for Systematic Reviews and Meta - Analyses), visando garantir transparência, rigor metodológico e reproduzibilidade.

2.1 Estratégia de Busca

A busca bibliográfica foi realizada em maio de 2025 nas bases de dados PubMed, MEDLINE e Biblioteca Virtual em Saúde (BVS/SciELO). Dois revisores independentes executaram a triagem inicial, e um terceiro revisor foi consultado em casos de discordância, foram considerados elegíveis estudos publicados entre 2015 e 2025 (últimos 10 anos), redigidos em inglês, espanhol ou português.

Foram utilizados descritores controlados (MeSH e Decs) e não controlados, combinados por operadores booleanos.

As strings de busca completas incluíram por exemplo:

PubMED/MEDLINE

(“magnetic Resonance” OR “MRI spectroscopy” OR “Magnetic Resonance Spectroscopy”) AND (glioma) AND (“Artificial Intelligence” OR “Machine Learning” OR “Deep Learning”)

BVS/SciELO

(“Ressonância Magnética” OR “Espectroscopia de Ressonância Magnética”) AND (glioma) AND (“Inteligência Artificial” OR

“Aprendizado de Máquina”)

2.2 Critérios de Inclusão e Exclusão

A seleção dos artigos foi norteada pelo modelo PICOS (População, Intervenção, Comparação, Desfecho, Desenho do Estudo) Tabela 1.

Tabela 1 - Estratégia Pico utilizada na Revisão.

População (P)	Pacientes com diagnósticos de gliomas
Intervenção (I)	Aplicação de Técnicas de Inteligência artificial (IA) em exames de Ressonância magnética (RM)
Comparação (C)	Estudos comparando o desempenho da IA com diagnósticos convencionais, ou entre diferentes modelos de IA.
Desfecho (O)	Desempenho diagnóstico utilizando a IA, por meio de métricas como acurácia, sensibilidade, especificidade.
Desenho do Estudo (S)	Estudos de revisão, publicados em artigos completos

Fonte: Elaborado pelos Autores.

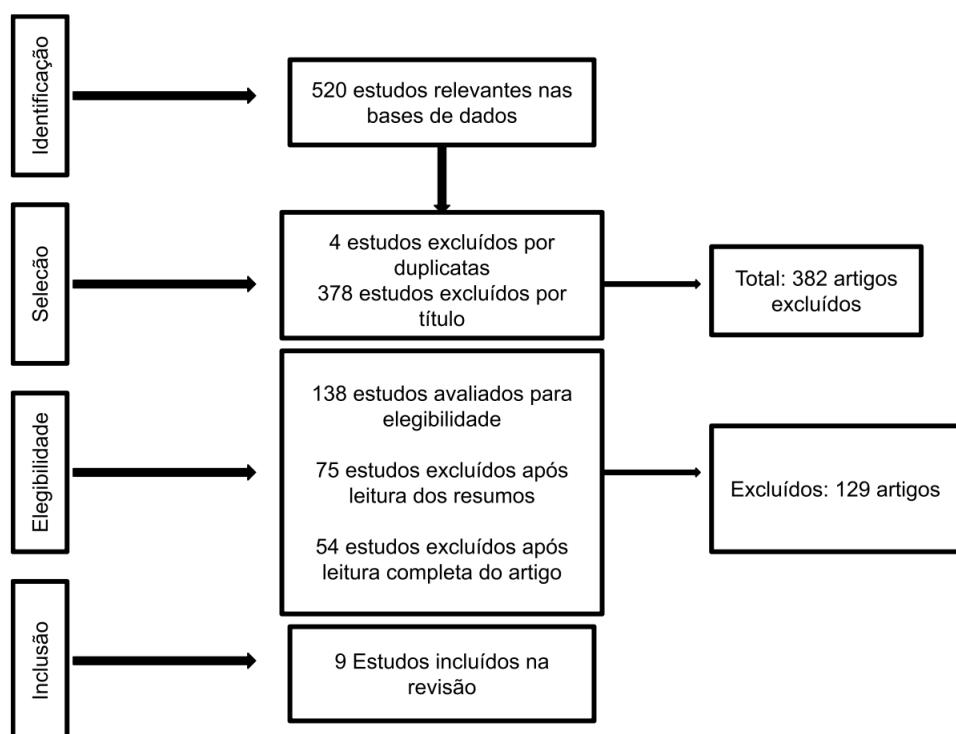
Foram considerados elegíveis para inclusão os estudos que envolvessem pacientes com diagnóstico confirmado de glioma, que aplicassem técnicas de inteligência artificial (IA) na análise de exames de ressonância magnética (RM), e que comparassem o desempenho de algoritmos de IA entre si ou em relação a métodos diagnósticos convencionais. Adicionalmente, exigiu-se que os trabalhos apresentassem relatos claros de métricas de desempenho, tais como acurácia, sensibilidade, especificidade e área sob a curva ROC (AUC).

Foram excluídos estudos conduzidos *in vitro* ou em modelos animais, bem como relatos de caso, editoriais, artigos de opinião, resumos de congressos e publicações redigidas em idiomas distintos daqueles previamente definidos. Também foram descartados artigos cuja metodologia não foi descrita de forma suficientemente clara para permitir a avaliação crítica de seus procedimentos e resultados.

2.3 Processo de seleção dos estudos

A busca nas bases de dados resultou em 520 registros relevantes. Após a remoção de 4 duplicatas, foram avaliados 516 artigos baseando-se em títulos. Nessa etapa foram excluídos no total 382 artigos. Na etapa de elegibilidade foram avaliados 138 estudos sendo 75 excluídos após a leitura dos resumos e 54 excluídos após a leitura do texto completo, totalizando em 129 artigos excluídos nesta etapa. Ao final, 9 estudos preencheram os critérios de elegibilidade e foram incluídos na síntese qualitativa. O processo de triagem e seleção está representado no fluxograma PRISMA (Figura 1).

Figura 1 - Fluxograma PRISMA.



Fonte: Elaborado pelos Autores.

2.4 Avaliação da qualidade

Dois revisores A.S e G.F realizaram de forma independente a avaliação de elegibilidade dos resultados da pesquisa, a qualidade metodológica dos estudos selecionados foi avaliada pelos mesmos revisores, utilizando a ferramenta AMSTAR-2 (Assessing the Methodological Quality of Systematic Reviews). Foram considerados sete domínios críticos: (I) registro de protocolo, (II) adequação da estratégia de busca, (III) avaliação do risco de viés, (IV) métodos estatísticos, (V) consideração de vieses nos resultados, (VI) avaliação de viés de publicação e (VII) confiança global da evidência. Cada item foi classificado como “SIM”, “NÃO” e “N/A”, e os estudos foram classificados quanto ao risco de viés global como: baixo, moderado, alto ou crítico com base nos critérios do AMSTAR-2.

2.5 Registro de Protocolo

O protocolo desta revisão não foi registrado em plataformas específicas, como o PROSPERO, o que representa uma limitação metodológica. Entretanto, todas as etapas foram descritas de forma transparente, visando reduzir potenciais vieses. Por se tratar de revisão baseada em dados secundários, não houve necessidade de aprovação por comitê de ética, mas foram seguidas diretrizes éticas para garantir transparência e confiabilidade.

3. Resultados e Discussão

A avaliação da qualidade metodológica dos estudos incluídos, realizada por meio da ferramenta AMSTAR-2, evidenciou uma heterogeneidade significativa nos padrões metodológicos. Apenas um estudo (5,9%) foi classificado como de alta confiança, enquanto sete (41,2%) apresentaram confiança moderada e outros sete (41,2%) foram considerados de baixa confiança. Dois estudos (11,7%) foram classificados como tendo confiança criticamente baixa. Os principais pontos de fragilidade observados incluíram a ausência de registro prévio de protocolo, lacunas na avaliação do risco de viés dos estudos primários e inconsistências na aplicação dos métodos estatísticos, conforme detalhado na Tabela 2.

Tabela 2 - Resumo da avaliação da ferramenta amstar-2 da literatura selecionada.

Autor (Ano)	Protocolo registrado? (Item 2)	Estratégia de busca adequada? (Item 4)	Avaliação risco de viés? (Item 9)	Métodos estatísticos corretos? (Item 11)	Considerou viés nos resultados? (Item 13)	Viés de publicação avaliado? (Item 15)	Nível de Confiança (Alta / Moderada / Baixa / Criticamente baixa)
Maria et.al (2024)	Não	Sim	Sim	Sim	Parcial	Sim	Moderado
Ayman S Alhasan (2021)	Sim	Parcial	Sim	N/A	Sim	Não	Moderado
Ayman S Alhasan (2021)	Sim	Parcial	Sim	N/A	Sim	Não	Moderado
Kempen et.al (2021)	Sim	Parcial	Sim	Sim	Sim	Sim	Alta
Chilaca-Rosas et.al (2025) 7	Não	Parcial	Sim	Sim	Sim	Sim	Moderado
Farahani et.al (2025)	Não	Sim	Sim	Sim	Sim	Sim	Moderado
Sohn et.al (2020)	Não	Parcial	Sim	Parcial	Sim	Sim	Moderado
Wang et.al (2023)	Não	Sim	Sim	Sim	Sim	Sim	Moderado
Al-Rumaihi et.al (2025)	Não	Sim	Sim	Sim	Sim	Sim	Moderado
Chen et.al (2024)	Sim	Sim	Sim	Sim	Sim	Sim	Alto

Fonte: Elaborado pelos Autores.

3.1 Características dos estudos incluídos

Os 9 estudos analisados abrangeram diferentes técnicas de IA aplicadas à RM no diagnóstico de gliomas, incluindo CNNs, máquinas de vetor de suporte (SVMs), Random Forest (RF), DL e abordagens de radiômica. A maioria dos artigos

avaliou desempenho diagnóstico para diferenciação de gliomas de baixo (LGG) e alto grau (HGG), bem como a previsão de marcadores moleculares.

Uma tabela padronizada foi desenvolvida para extração de dados, os seguintes dados foram retirados de cada estudo incluído por dois revisores de forma independente. Autor (Ano), Tipo de Estudo, Objetivo do Estudo, Técnicas de IA utilizadas e Resultados. Tabela 3

Tabela 3 - Resumo dos Resultados avaliados nos estudos revisados.

Autor (Ano)	Tipo de Estudo	Objetivo	Técnicas de IA	Resultados
Maria et.al (2024)	Revisão Sistemática	Avaliar desempenho diagnóstico da radiômica baseada em RM para classificação de gliomas.	RF SVM	SVM e RF tiveram desempenho superior aos métodos estatístico tradicionais. ótima capacidade de distinguir HGG de LGG mas risco de confundir LGG com HGG.
Ayman S Alhasan (2021)	Revisão Sistemática	Avaliar modelos de DL na classificação de gliomas por RM	CCNs, Redes Neurais profundas recorrentes (RNNs), Redes Neurais auto codificadoras (DA), Redes Neurais de crenças Profundas (DBN)	CNNs (um dos modelos de DP) modelo mais eficaz mostrado nos estudos, no processo de amadurecimento para ser usada nos diagnósticos e tratamento de gliomas
van Kempen et al. (2021)	Revisão Sistemática	Avaliar o desempenho de algoritmos de ML na segmentação de gliomas em RM	ML	Acurácia boa, porém alta heterogeneidade diferença nos pacientes, nas imagens, equipamentos e dos algoritmos
Chilaca-Rosas et.al (2025)	Revisão Sistemática	Avaliar a integração de IA e radiômica para prever a progressão de gliomas de alto grau e aprimorar o manejo clínico	SVM e RF	SVM e RF alto desempenho com até 98% AUC e 98,7% de acurácia.
Farahani et al. (2025)	Revisão Sistemática	Avaliar a precisão diagnóstica de modelos de DL na previsão de marcadores moleculares de glioma utilizando RM	CNNs, Redes Neurais Profundas (DNN's), SVMs e RF	DL apresenta resultados significativos na previsão de marcadores moleculares do glioma, porém desafiada pela heterogeneidade de dados, limitações operacionais e barreiras regulatórias.
Sohn et.al (2020)	Revisão Sistemática	Estimar precisão diagnóstica da radiomia baseada ML na diferenciação de gliomas e identificar possíveis variáveis que afetam precisão diagnóstica	Radiômica combinada com ML.	A combinação da radiomia com ML para diagnósticos e na diferenciação de HGG e LGG teve um ótimo desempenho.
Chen et.al (2024)	Revisão Sistemática	Avaliar a acurácia de modelos radiómicos baseados em aprendizado de máquina para prever mutações IDH em gliomas e avaliar a qualidade metodológica dos estudos	SVM, RF	Modelos de ML superaram DL, LGG com sensibilidade maior, HGG com especificidade maior e radiômica combinada com dados clínicos melhora a sensibilidade.
Al-Rumaihi (2025)	Revisão Sistemática	examinar e comparar a aplicação de diferentes técnicas de IA para diagnósticos de vários tipos de tumores cerebrais através da RM.	CNN's,SVM,	Técnicas de CNN's com alta precisão de na classificação dos tipos de tumores, heterogeneidade continua sendo um problema é necessária uma padronização sendo o desafio atual.
Wang et.al (2023)	Revisão Sistemática	Examinar o valor diagnóstico da radiômica aplicada a ressonância magnética na diferenciação de gliomas HGG e LGG.	Radiômica	Radiômica é uma técnica precisa para a diferenciação dos gliomas, porém ainda enfrenta desafios.

Fonte: Elaborado pelos Autores.

Os estudos demonstraram um foco significativo na integração da inteligência Artificial, Aprendizado de máquina (ML) e Aprendizado Profundo com a Radiômica (AIR) para aprimorar o diagnóstico, prognóstico e manejo de gliomas, que são tumores agressivos do sistema nervoso central. Todos os estudos ressaltam a importância de métodos não invasivos para avaliar esses tumores, visto que a biópsia, embora seja o padrão ouro, apresenta riscos e limitações.

3.2 Classificação e Graduação de gliomas

Os modelos de IA demonstram elevada acurácia na diferenciação de gliomas de alto grau (HGG) e baixo grau (LGG).

Dos resultados encontrados, a sensibilidade agrupada para diagnosticar HGG teve um resultado de 96%. A especificidade para diagnosticar LGG teve um resultado mais baixo de 90%. No entanto, a diferenciação do grau 4 e do grau 3

do glioma da OMS apresentou desempenho ligeiramente inferior (sensibilidade de 89%, especificidade de 81%) (Chilaca-Rosas et al., 2025; Sohn & Bisdas, 2020).

Sobre a previsão de marcadores moleculares, esta é uma área de pesquisa em rápido crescimento, com modelos de DL/ML sendo usados para prever o status de mutações genéticas importantes, que tradicionalmente exigem procedimentos invasivos. Em relação a mutações mais recentes de interesse clínico, como ATRX e TERT, os estudos reportam sensibilidade e especificidade agrupadas de 0,79/0,85 para ATRX e 0,81/0,70 para TERT, respectivamente (Farahani et al., 2025)

Na segmentação tumoral, algoritmos de aprendizado de máquina em especial CNNs (redes neurais convolucionais), apresentaram desempenho consistente, com coeficientes de DICE (DSC) médio de 0,84 mostrando resultados semelhantes entre gliomas de alto grau (HGG) e baixo grau (LGG) (van Kempen et al., 2021)

Por fim, a integração de IA e radiômica também foi aplicada à predição de sobrevida global (OS) e sobrevida livre de progressão (PFS). Alguns modelos como SVM e RF alcançaram desempenho notável, com AUC de até 98% e acurácia de 98,7% (Chilaca-Rosas et al., 2025). O avanço da DL tem se consolidado como marco na análise de imagens médicas, sobretudo por meio das CNNs, essa abordagem tornou-se predominante devido à sua capacidade de processar dados brutos de RM, oferecendo ganhos significativos na caracterização e interpretação das imagens (Alhasan, 2021). Paralelamente, os algoritmos de ML como SVM e RF, continuam a se destacar como ferramentas de alto desempenho, principalmente em tarefas relacionadas à graduação de gliomas e à predição de OS e PFS a partir dos resultados de AUC e acurácia como foram citados (Chilaca-Rosas et al., 2025).

Mas recentemente, observa-se uma tendência crescente para o desenvolvimento de modelos híbridos que integram características radiômicas e de DL, bem como o uso de estratégias de Ensemble. Esses modelos têm demonstrado desempenho robusto, com alta acurácia e estabilidade, alcançado, por exemplo, 95,28% de acurácia na segmentação de gliomas (Al-Rumaihi et al., 2025)

As características radiômicas de primeira e segunda ordem têm se mostrado amplamente preditivas para a graduação e caracterização dos gliomas. Essas variáveis permitem captar aspectos relacionados a heterogeneidade tumoral, distribuição espacial e padrões de textura que não são perceptíveis na análise visual convencional de imagens (Chilaca-Rosas et al., 2025).

Entre as características de segunda ordem se destaca Gray Level Co-occurrence Matrix (GLCM), Gray Level Dependence Matrix (GLDM), Neighboring Gray-Tone Difference Matrix (NGTDM), Gray Level Run Length Matrix (GLRLM), Gray Level Size Zone Matrix (GLSZM). Segundo a autora Chilaca et.al tais descritores de textura foram empregados em 68% dos estudos revisado, demonstrando alta capacidade de prever a diferenciação e caracterização dos gliomas, por meio de análises das relações espaciais entre os voxels na região de interesse (Chilaca-Rosas et al., 2025).

As características da primeira ordem, como Kurtose, energia de área necrótica e desvio padrão de intensidade, associados a atributos de forma, volume e variáveis clínicas e moleculares (exemplos: idade, mutações em IDH e metilação do promotor de MGMT), também apresentaram relevância prognóstica, sendo associadas à prognosticar a OS e PFS (Chilaca-Rosas et al., 2025). Além disso, parâmetros derivados da difusão, como ADC (coeficiente de difusão aparente), demonstraram utilidade na classificação de gliomas LGG (Sohn & Bisdas, 2020). A integração de dados radiômicos com informações clínicas e moleculares mostrou-se uma estratégia eficaz para aprimorar a acurácia preditiva e reduzir vieses, favorecendo a detecção precoce de progressão tumoral, porém não foram todos os estudos que incluíram. De fato, aproximadamente 58% dos estudos analisados incorporaram dados moleculares, como mutações e alterações genéticas, em seus modelos de predição (Chilaca-Rosas et al., 2025).

As classificações da OMS de 2016 e 2021 reforçam a importância de biomarcadores moleculares, incluindo os principais marcadores IDH, 1p/19q e os demais por exemplo ATRX, TERT, TP53.CDKN2A/B, EGFR. Ki-67, SYP, como elementos fundamentais para diagnósticos, definição prognóstica e escolha terapêutica nos gliomas (De Maria et al., 2024; Farahani et al., 2025; Saúde, n.d.)

3.3 Uso de imagens multimodais

A ressonância magnética (RM) permanece como o padrão-ouro para a visualização tumoral e avaliação da resposta terapêutica em pacientes com gliomas. Técnicas avançadas, como a perfusão (PWI) e a difusão (DWI), têm ampliado a compreensão da biologia tumoral, oferecendo informações complementares sobre vascularização, densidade celular e microambiente do tumor (Chilaca-Rosas et al., 2025). A relevância da RM decorre de sua aplicabilidade clínica consolidada, além da capacidade de capturar múltiplos aspectos da morfologia e da fisiopatologia tumoral em diferentes sequências (Farahani et al., 2025). As sequências de RM mais frequentemente recomendadas incluem T1-weighted (T1W), T1 com contraste (CE-T1WI), T2-weighted (T2W) e FLAIR, sendo estas últimas, em especial CE-T1WI, T1 e FLAIR, consideradas essenciais para a segmentação automática de gliomas (Chilaca-Rosas et al., 2025).

Estudos baseados em imagens multimodais demonstraram maior especificidade na diferenciação entre gliomas LGG e HGG (Sohn & Bisdas, 2020). Ademais, a sequência CE-T1W foi a mais frequentemente utilizada em modelos de DL para a predição de marcadores moleculares, ressaltando sua importância na integração de imagem e genômica (Farahani et al., 2025).

Apesar dos avanços, ainda persiste uma falta de consenso quanto aos protocolos ideais de aquisição de imagens, às metodologias de segmentação e à interpretabilidade dos modelos de inteligência artificial, fatores que comprometem a reprodutibilidade e a aplicação clínica em larga escala. Dessa forma, torna-se imperativo o estabelecimento de diretrizes padronizadas que norteiam a aquisição, o processamento e a análise radiométrica, bem como a validação multicêntrica dos modelos. A proposta de um roteiro estruturado para o desenvolvimento de modelos AIRI (Artificial Intelligence Radiomics Inter-field) tem sido apontada como uma estratégia promissora para reduzir vieses e garantir a comparabilidade entre os estudos (Chilaca-Rosas et al., 2025).

Há padronização em todas as etapas do processo (incluindo aquisição das imagens, segmentação, engenharia de características, análises estatísticas e estruturação de relatórios) representa um passo fundamental para promover a generalização e a confiabilidade dos estudos radiométricos baseados em ML (Sohn & Bisdas, 2020). Ainda assim, a heterogeneidade metodológica permanece como uma das principais limitações, abrangendo variações nos protocolos de imagem, nas técnicas de segmentação e nas estratégias de seleção de características. Esses aspectos reforçam a necessidade de adotar estruturas AIRI consolidadas e padronizadas, a fim de melhorar tanto a comparabilidade dos achados quanto sua aplicabilidade translacional (Chilaca-Rosas et al., 2025).

Segundo a literatura que aponta significativa heterogeneidade nos estudos atuais, refletida em métricas e indicadores de desempenho diversos, o que dificulta a integração e comparação dos resultados (Chilaca-Rosas et al., 2025). Essa variação está relacionada a múltiplos fatores, como diferenças nos protocolos de aquisição de imagens, metodologias de segmentação, técnicas de extração de características e métodos de validação (Farahani et al., 2025). Além disso, discrepâncias em protocolos de RM, técnicas de pré-processamento e tipos de hardware utilizados entre centros tornam a padronização ainda mais desafiadora (Al-Rumaihi et al., 2025).

Outro desafio crítico é a reprodutibilidade dos resultados, frequentemente comprometida pela ausência de padronização na extração de características e na validação dos modelos (Chilaca-Rosas et al., 2025). Estudos de avaliação de qualidade, como o QUADS-2, identificaram vieses em múltiplas etapas do processo, além de preocupações com a aplicabilidade clínica em contextos de validação externa (Farahani et al., 2025; Wang et al., 2023).

Grande parte dos trabalhos apresenta delineamento retrospectivo, no qual os desfechos dos pacientes já são conhecidos, acarretando risco elevado de viés de seleção. O uso de bases públicas de dados, embora facilite o acesso e reuso científico, também pode introduzir vieses adicionais, uma vez que nem todos os fatores relacionados à aquisição das imagens podem ser controlados (Sohn & Bisdas, 2020).

Os modelos DL frequentemente se mostram suscetíveis ao overfitting (fenômeno que ocorre quando um modelo de aprendizado aprende os dados de um treinamento de uma forma excessivamente detalhadas, sendo difícil a generalização para novos dados), especialmente quando a seleção de características é realizada em dados também utilizados para teste em validação cruzada (Chilaca-Rosas et al., 2025). Estratégias de redução dimensional e seleção criteriosa de variáveis têm sido recomendadas para mitigar esse problema e aumentar a robustez dos modelos (Sohn & Bisdas, 2020). Ademais, a homogeneidade de conjuntos de dados públicos, como a segmentação do tumor, pode exacerbar o risco de overfitting e limitar a capacidade de generalização (Al-Rumaihi et al., 2025).

Grande parte dos estudos não contempla validação externa ou a utilização de conjuntos de teste independentes, etapa crucial para avaliar a robustez e generalização dos modelos em cenários do mundo real (Al-Rumaihi et al., 2025; Chilaca-Rosas et al., 2025; Farahani et al., 2025; van Kempen et al., 2021). Quando presente, a validação externa tende a revelar desempenho inferior em termos de sensibilidade e especificidade, em comparação à validação interna (Chen et al., 2024).

O tamanho amostral reduzido e o desequilíbrio entre gliomas de baixo e alto grau comprometem a separação adequada entre conjuntos de validação e teste, além de aumentar o risco de overfitting (Al-Rumaihi et al., 2025; Sohn & Bisdas, 2020). Nesse contexto, modelos baseados em DL frequentemente apresentam desempenho inferior em conjuntos reduzidos de dados, quando comparados aos modelos tradicionais de ML (Chen et al., 2024). Torna-se, portanto, imprescindível a criação de bases de dados mais amplas e diversificadas (Al-Rumaihi et al., 2025).

A ausência de clareza e padronização nos relatórios metodológicos também representa um obstáculo. Muitas vezes, os resultados são apresentados de forma aglomerada ou com abreviações não padronizadas, comprometendo a transparência e a reproduzibilidade (Al-Rumaihi et al., 2025; Chilaca-Rosas et al., 2025). Apesar do grande potencial, a tradução dos modelos desenvolvidos em pesquisa para a prática clínica ainda encontra barreiras significativas, principalmente relacionadas à falta de padronização, à escassez de validação robusta e à dificuldade em reproduzir resultados (De Maria et al., 2024). Até o momento, a implementação clínica em larga escala permanece limitada (van Kempen et al., 2021).

As constantes atualizações nas classificações da OMS para tumores do sistema nervoso central, como as transições de 2016 para 2021, podem gerar um desvio de dados, resultando em perda de precisão de modelos treinados com critérios antigos. Assim, a atualização periódica e readequação dos modelos torna-se fundamental para manter sua validade clínica (De Maria et al., 2024).

A natureza de “caixa-preta” dos modelos DL ainda constitui um desafio relevante, uma vez que o processo interno de tomada de decisão não é transparente. Essa limitação compromete a confiança do clínico e a responsabilização em casos de erros diagnósticos (Al-Rumaihi et al., 2025; Farahani et al., 2025). Em particular, a baixa interpretabilidade das CNN’s pode reduzir a aceitação clínica, sobretudo em situações de falsos negativos (Al-Rumaihi et al., 2025).

É prioritária a realização de estudos prospectivos com amostras amplas e diversas, capazes de gerar modelos de IA mais generalizáveis e validados em diferentes populações (Al-Rumaihi et al., 2025; Chen et al., 2024). Além disso, avaliações rigorosas dos protocolos de ML e DL são fundamentais para reduzir vieses e consolidar a robustez das evidências (Alhasan, 2021). A implementação de roteiros universais e diretrizes padronizadas para o desenvolvimento de modelos AIRI (incluindo aquisição de dados, pré-processamento, segmentação e extração de características) é uma necessidade urgente (Chilaca-Rosas et al., 2025; Sohn & Bisdas, 2020). A harmonização de dados, sobretudo em iniciativas de ciência aberta, permitirá maximizar o potencial das bases públicas e fortalecer a confiabilidade das análises radiométricas (Saúde, n.d.; van Kempen et al., 2021).

A combinação de informações clínicas e moleculares (como idade, status funcional, IDH e MGMT) com dados de imagem avançados tem se mostrado uma estratégia promissora para aumentar o desempenho e a acurácia dos modelos preditivos (Al-Rumaihi et al., 2025; Chilaca-Rosas et al., 2025; Sohn & Bisdas, 2020). A disponibilização de algoritmos, códigos e dados em acesso aberto deve ser incentivada, a fim de fomentar a colaboração interdisciplinar e acelerar o avanço do campo (Alhasan,

2021; Chilaca-Rosas et al., 2025; van Kempen et al., 2021). Iniciativas de compartilhamento de dados e o desenvolvimento de plataformas colaborativas internacionais são essenciais para o fortalecimento da pesquisa global em radiômica aplicada aos gliomas (Chilaca-Rosas et al., 2025).

No diagnóstico de gliomas, a RM (Ressonância Magnética) com a aplicação da IA (Inteligência Artificial), oferece em termos de acurácia, eficiência diagnóstica e prognóstico. Por meio das ponderações/sequências T1, T2, FLAIR e contraste com gadolinio, que são métodos convencionais para a patologia em questão (Saúde, n.d.) No entanto, há limitações devido às diferenciações de gliomas, alto ou baixo grau, seja na ausência de saturação pelo contraste (Alhasan, 2021).

Os métodos baseados em IA, têm demonstrado maior sensibilidade e especificidade na constatação de arquétipos sutis e variedades intratumorais que não são evidentes à análise radiológica convencional. Através de aspectos quantitativos por meio de radiômica, favorecendo a classificação tumoral e, em alguns casos, o indicador de marcadores moleculares, como IDH e 1p/19q (Chilaca-Rosas et al., 2025; van Kempen et al., 2021).

O engajamento da IA nesses métodos permite mecanizar e uniformizar a análise, diminuindo a variedade da repetibilidade das observações e aumentando a autenticidade dos laudos, com isso, corrobora a importância dos métodos avançados de imagens, como RM funcional, espectroscopia e perfusão (Alhasan, 2021; Farahani et al., 2025).

Apesar dos avanços significativos, há limitações nesses métodos, que precisam de softwares com grandes bancos de dados e rotulagens para essa padronização de diagnóstico em questão, sendo assim, uma incitação tanto técnica quanto ética, visando a confidencialidade dos pacientes. Nesse conceito, há restrições na disseminação dos padrões de IA, uma vez que sequências de instruções(algoritmos) exibem um ato curto quando empregados em populações ou variedade de equipamentos usados em prática (Farahani et al., 2025; van Kempen et al., 2021).

A CONITEC (2020), apesar das altas taxas de acurácia reportadas (até 98%), não reconhece formalmente ferramentas respaldadas em IA como elemento de normas clínicas para tumores cerebrais, ponderando um intervalo entre o avanço científico e o engajamento no sistema público de saúde (De Maria et al., 2024). A inclusão dessas tecnologias requer, além de indícios concretos de custo-efetividade, políticas públicas que rege o uso com segurança e equidade. O uso da IA e RM para diagnóstico de gliomas, há uma controvérsia entre, a competência para transformar diagnóstico neuro-oncológico; e a comprovação clínica, prescrição e infraestrutura para sua consumação (Chilaca-Rosas et al., 2025). Seja para combinação de acréscimo de soluções híbridas, e automatizadas e aptidão médica, podendo representar um meio viável no curto prazo, enquanto a ciência prossegue para ultrapassar os desafios presentes.

Um avanço tecnológico com o uso da IA, representa um salto qualitativo no prognóstico e identificação de gliomas na RM, sendo uma ferramenta para favorecer o trabalho clínico - mesmo com limitações, torna-se uma grande aliada para fins de tratamento e soluções mais concretas para o paciente (Chilaca-Rosas et al., 2025; van Kempen et al., 2021)

4. Conclusão

A inteligência artificial aplicada à ressonância magnética representa um avanço significativo no diagnóstico e prognóstico de gliomas, com desempenho superior ao da análise radiológica convencional em diversos cenários. Técnicas como DL, ML e radiômica demonstraram alta acurácia na diferenciação de gliomas de baixo e alto grau, além da capacidade de prever mutações genéticas relevantes, como IDH e 1p/19q. Modelos híbridos, que combinam imagens multimodais com dados clínicos e moleculares, surgem como a estratégia mais promissora, com taxas de acurácia superiores a 95%. Apesar desses progressos, desafios importantes persistem: a heterogeneidade dos protocolos de aquisição de imagens, a falta de padronização nos métodos analíticos, a escassez de validação externa e questões éticas e regulatórias. No contexto brasileiro, a ausência de reconhecimento formal pela CONITEC e a necessidade de comprovação de custo-efetividade reforçam a lacuna entre pesquisa e implementação clínica.

Portanto, embora os resultados atuais reforcem o potencial transformador da IA como ferramenta diagnóstica, sua consolidação na prática clínica exige diretrizes internacionais padronizadas, estudos multicêntricos robustos e integração com políticas públicas de saúde. A médio prazo, a IA tende a se consolidar como suporte essencial ao diagnóstico neuro-oncológico, favorecendo decisões terapêuticas mais seguras e personalizadas.

Agradecimentos

Agradecemos à parceria entre as autoras, ao orientador, pela orientação científica e contribuições fundamentais, à Faculdade de Medicina do ABC (FMABC) e ao curso de Biomedicina pelo suporte institucional e formativo, bem como ao estágio realizado, que contribuiu significativamente para o desenvolvimento acadêmico e científico deste estudo.

Referências

- Alhasan, A. S. (2021). Clinical Applications of Artificial Intelligence, Machine Learning, and Deep Learning in the Imaging of Gliomas: A Systematic Review. *Cureus*. 13(11):e19580. doi: 10.7759/cureus.19580. eCollection 2021 Nov.
- Al-Rumaihi, G., Khan, M. M., Saleh, A., Ali, A., Al-Rumaihi, L., Al-Jaber, N. et al. (2025). Performance Evaluation of Artificial Intelligence Techniques in the Diagnosis of Brain Tumors: A Systematic Review and Meta-Analysis. *Cureus*. 17(7):e88915. doi: 10.7759/cureus.88915. eCollection 2025 Jul.
- Bonm, A. V., Ritterbusch, R., Throckmorton, P. & Graber, J. J. (2020). Clinical Imaging for Diagnostic Challenges in the Management of Gliomas: A Review. *Journal of Neuroimaging*. 30(2):139–45.
- Brasil. (2020). Diretrizes diagnósticas e terapêuticas de tumor cerebral no adulto. <http://conitec.gov.br/>. https://www.gov.br/conitec/pt-br/mídias/protocolos/publicações_ms/20201218_pc当地肿瘤脑部成人isbn.pdf.
- Chen, X., Lei, J., Wang, S., Zhang, J. & Gou, L. (2024). Diagnostic accuracy of a machine learning-based radiomics approach of MR in predicting IDH mutations in glioma patients: a systematic review and meta-analysis. *Front Oncol*. 14:1409760. doi: 10.3389/fonc.2024.1409760. eCollection 2024.
- Chilaca-Rosas, M. F., Contreras-Aguilar, M. T., Pallach-Loose, F., Altamirano-Bustamante, N. F., Salazar-Calderon, D. R., Revilla-Monsalve, C., et al. (2025). Systematic review and epistemic meta-analysis to advance binomial AI-radiomics integration for predicting high-grade glioma progression and enhancing patient management. *Sci Rep*. 15(1):16113.
- Crossetti, M. G. O. (2012). Revisão integrativa de pesquisa na enfermagem o rigor científico que lhe é exigido. *Rev Gaúcha Enferm*. 33(2):8-9. <https://www.scielo.br/j/rgenf/a/9TrSVHTDtDGhcP5pLvGnt5n/?format=pdf&lang=pt>.
- De Maria, L., Ponzio, F., Cho, H., Sogen, K., Tsougos, I., Gasparini, M. et al. (2024). The Current Diagnostic Performance of MRI-Based Radiomics for Glioma Grading: A Meta-Analysis. *J Integr Neurosci*. 23(5).
- Maia Jr, A. C. M. (2005). Avaliação da contribuição do estudo de perfusão por ressonância magnética para o diagnóstico pré-operatório de anaplasia em tumores supratentoriais com aspecto sugestivo de glioma sem impregnação pelo agente paramagnético na ressonância magnética convencional. Tese (Doutorado). Universidade Federal de São Paulo-Escola Paulista de Medicina.
- Farahani, S., Hejazi, M., Moradizeyveh, S., Di Ieva, A., Fatemizadeh, E. & Liu, S. (2025). Diagnostic Accuracy of Deep Learning Models in Predicting Glioma Molecular Markers: A Systematic Review and Meta-Analysis. *Diagnostics*. 15(7):797.
- Luo, J., Pan, M., Mo, K., Mao, Y., Zou, D. (2023). Emerging role of artificial intelligence in diagnosis, classification and clinical management of glioma. *Semin Cancer Biol*. 91:110–23.
- Mehmandoost, M., Konjin, F. T., Jajin, E. A., Fahim, F., Yazdani, S. O. (2024). A review on the applications of artificial intelligence and big data for glioblastoma multiforme management. *Egyptian Journal of Neurosurgery*. 39(1):51.
- Ostrom, Q. T., Bauchet, L., Davis, F. G., Deltour, I., Fisher, J. L., Langer, C. E. et al. (2014). The epidemiology of glioma in adults: a “state of the science” review. *Neuro Oncol*. 16(7):896–913.
- Pereira, A. S., Shitsuka, S. M., Parreira, F. J. & Shitsuka, R. (2020). Metodologia da pesquisa científica. Santa Maria. Editora da UFSM.
- Risemberg, R. I. C., Wakin, M., & Shitsuka, R. (2026). A importância da metodologia científica no desenvolvimento de artigos científicos. *E-Acadêmica*, 7(1), e0171675. <https://doi.org/10.52076/eacad-v7i1.675>.
- Shukla, G., Alexander, G. S., Bakas, S., Nikam, R., Talekar, K., Palmer, J. D. et al. (2017). Advanced magnetic resonance imaging in glioblastoma: a review. *Chin Clin Oncol*. 6(4):40–40.
- Snyder H. (2019). Literature review as a research methodology: An overview and guidelines. *J Bus Res*. 104:333–9.
- Sohn, C. K. & Bisdas, S. (2020). Diagnostic Accuracy of Machine Learning-Based Radiomics in Grading Gliomas: Systematic Review and Meta-Analysis. *Contrast Media Mol Imaging*. 2020:1–12.

Song, H. R., Gonzalez-Gomez, I., Suh, G. S., Commins, D. L., Spoto, R., Gilles, F. H. et al. (2010). Nuclear factor IA is expressed in astrocytomas and is associated with improved survival. *Neuro Oncol.* 12(2):122–32.

Tomás, A. & Pojo, M. (2025). PIK3CA Mutations: Are They a Relevant Target in Adult Diffuse Gliomas? *Int J Mol Sci.* 26(11):5276.

van Kempen, E. J., Post, M., Mannil, M., Witkam, R. L., ter Laan, M., Patel, A. et al. (2021). Performance of machine learning algorithms for glioma segmentation of brain MRI: a systematic literature review and meta-analysis. *Eur Radiol.* 31(12):9638–53.

Wang, J., Chen, Z. & Chen, J. (2023). Diagnostic value of MRI radiomics in differentiating high-grade glioma from low-grade glioma: A meta-analysis. *Oncol Lett.* 26(4):436.

Xu, J., Meng, Y., Qiu, K., Topatana, W., Li, S., Wei, C. et al. (2022). Applications of Artificial Intelligence Based on Medical Imaging in Glioma: Current State and Future Challenges. *Front Oncol.* 12:892056. doi: 10.3389/fonc.2022.892056. eCollection 2022.