ReGeo ISSN: 2177-3246

MODELOS DE LINGUAGEM DE GRANDE ESCALA (LLMs) EM RADIOLOGIA: GERAÇÃO DE VALOR ENTRE EFICIÊNCIA DIAGNÓSTICA E HUMANIZAÇÃO

LARGE LANGUAGE MODELS (LLMs) IN RADIOLOGY: CREATING VALUE THROUGH A BALANCE OF DIAGNOSTIC EFFICIENCY AND HUMANIZATION

MODELOS DE LENGUAJE DE GRAN ESCALA (LLM) EM RADIOLOGÍA: GENERACIÓN DE VALOR ENTRE LA EFICIENCIA DIAGNÓSTICA Y LA HUMANIZACIÓN

https://doi.org/10.56238/revgeov17n11-075

Data de submissão: 15/10/2026 **Data de publicação:** 15/11/2026

Pedro Figueiredo Gama
Instituição: Hospital de Amor Amazônia, Universidade Federal de Rondônia (UNIR)
Endereço: Porto Velho, Rondônia, Brasil
E-mail: pedrofgama@terra.com.br

Luis Gustavo Terra Cruz
Instituição: Hospital de Amor Amazônia
Endereço: Porto Velho, Rondônia, Brasil
E-mail: gustavoterracruz@gmail.com

Vanessa Santos Marinho
Instituição: Hospital de Amor Amazônia
Endereço: Porto Velho, Rondônia, Brasil
E-mail: dravanessasantosmarinho@gmail.com

Felipe Rodrigues Pontes
Instituição: Hospital de Amor Amazônia
Endereço: Porto Velho, Rondônia, Brasil
E-mail: rpontesfelipe@gmail.com

Humberto Oliart Guzman
Instituição: Hospital de Amor Amazônia
Endereço: Porto Velho, Rondônia, Brasil
E-mail: franyavo19@gmail.com

Vinicius Cardoso dos Santos
Instituição: Hospital de Amor Amazônia
Endereço: Porto Velho, Rondônia, Brasil
E-mail: vicocs@yahoo.com.br

Murilo Augusto Maciel
Instituição: Hospital de Amor Amazônia
Endereço: Porto Velho, Rondônia, Brasil
E-mail: murilo_augusto@yahoo.com.br

RESUMO
Este ensaio analisa criticamente o papel dos *Large Language Models* (LLMs) na radiologia contemporânea, enfatizando a tensão entre eficiência diag-nóstica e humanização do cuidado. A partir do conceito de valor em saúde (*value-based healthcare*) proposto por Porter (2010) e Kaplan e Porter (2011), o texto discute como a incorporação dos LLMs amplia o escopo da inteligência artificial, deslocando a radiologia de uma prática visual para uma prática discursiva e mul-timodal. Os modelos de linguagem, ao integrarem texto, imagem e decisão clí-nica, oferecem suporte interpretativo, reduzem redundâncias e democratizam o acesso à informação médica. Entretanto, sua adoção suscita dilemas éticos, ris-cos de viés e desafios relacionados à autonomia profissional. Defende-se que o radiologista deve assumir um papel mediador entre inteligências humana e arti-ficial, reforçando a necessidade de formação ética e letramento digital clínico. Conclui-se que os LLMs só gerarão valor sustentável quando alinhados à ética do cuidado e à centralidade do paciente, promovendo uma medicina em que tecnologia e humanidade coexistam de modo complementar.

Palavras-chave: Radiologia. Inteligência Artificial. Modelos de Linguagem. Valor em Saúde. Humanização.

ABSTRACT
This essay critically examines the role of Large Language Models (LLMs) in contemporary radiology, focusing on the tension between diagnostic efficiency and the humanization of care. Grounded in Porter's (2010) and Kaplan & Porter's (2011) value-based healthcare framework, it argues that LLMs expand artificial intelligence from visual analysis to a multimodal and discursive practice. By integrating text, image, and clinical reasoning, LLMs enhance interpretive support, reduce redundancies, and democratize access to medical knowledge. However, their implementation raises ethical concerns, bias risks, and challenges to professional autonomy. The essay contends that radiologists must act as media-tors between human and artificial intelligence, emphasizing ethical training and clinical digital literacy. It concludes that LLMs will only generate sustainable value when aligned with the ethics of care and patient-centered medicine, where technology and humanity coexist as complementary dimensions.

Keywords: Radiology. Artificial Intelligence. Language Models. Value-Based Healthcare. Humanization.

RESUMEN
Este ensayo analiza críticamente el papel de los Grandes Modelos de Lenguaje (LLM, por sus siglas en inglés) en la radiología contemporánea, enfatizando la tensión entre la eficiencia diagnóstica y la humanización de la atención. A partir del concepto de valor en salud (value-based healthcare) propuesto por Porter (2010) y Kaplan y Porter (2011), el texto discute cómo la incorporación de los LLM amplía el alcance de la inteligencia artificial, desplazando la radiología de una práctica visual hacia una práctica discursiva y multimodal. Los modelos de lenguaje, al integrar texto, imagen y decisión clínica, ofrecen apoyo interpretativo, reducen redundancias y democratizan el acceso a la información médica. Sin embargo, su adopción plantea dilemas éticos, riesgos de sesgo y desafíos relacionados con la autonomía profesional. Se sostiene que el radiólogo debe asumir un papel mediador entre la inteligencia humana y la artificial, reforzando la necesidad de una formación ética y de competencias digitales clínicas. Se concluye que los LLM solo generarán un valor sostenible cuando estén alineados con la ética del cuidado y la centralidad del paciente, promoviendo una medicina en la que la tecnología y la humanidad coexistan de manera complementaria.

Palabras clave: Radiología. Inteligencia Artificial. Modelos de Lenguaje. Valor en Salud. Humanización.

1 INTRODUÇÃO

A radiologia consolidou-se historicamente como um dos campos mais receptivos à inovação tecnológica na medicina. Desde a incorporação dos primeiros sistemas de detecção automatizada até as atuais aplicações de aprendizado profundo, o campo tornou-se um laboratório privilegiado para observar a interação entre inteligência humana e inteligência artificial (IA) (Kelly et al., 2022).

Nos últimos anos, a ascensão dos *Large Language Models* (LLMs) vem ampliando ainda mais essa fronteira, introduzindo uma dimensão linguística e interpretativa à prática radiológica. Diferentemente dos modelos de visão computacional, restritos à análise de pixels e padrões visuais, os LLMs operam no domínio da linguagem natural, integrando dados clínicos, relatórios e imagens em uma mesma arquitetura de raciocínio contextual (D'Antonoli et al., 2024).

Essa capacidade representa, como dizem os mesmos autores, não apenas um avanço técnico, mas uma mudança de paradigma: a radiologia passa de uma prática essencialmente visual para uma prática discursiva e multimodal, em que o texto, a fala e a imagem se entrelaçam na produção de sentido diagnóstico.

O impacto dessa transformação é profundo. Na literatura recente, autores como D'Antonoli et al. (2024) e Wang e Zhang (2024) destacam que os LLMs podem facilitar a comunicação entre profissionais de saúde, pacientes e familiares, bem como atuar como interfaces de linguagem natural que simplificam o acesso a sistemas complexos de radiologia. Essa integração promete ganhos expressivos de eficiência diagnóstica, redução de redundâncias e democratização do conhecimento clínico.

Ao mesmo tempo, suscita questionamentos éticos, epistemológicos e práticos: até que ponto a automação pode contribuir para o valor em saúde sem comprometer a dimensão humana da prática médica? O problema central, portanto, não é apenas tecnológico, mas filosófico e organizacional, trata-se de compreender como os LLMs podem gerar valor sustentável em radiologia sem reduzir o papel interpretativo, empático e ético do radiologista.

Diante desse cenário, este ensaio tem como objetivo discutir criticamente o papel dos LLMs na radiologia contemporânea, analisando suas contribuições para a geração de valor em saúde à luz da tensão entre eficiência diagnóstica e humanização do cuidado. Busca-se examinar de que modo essas tecnologias, ao mediar a comunicação entre imagem, linguagem e decisão clínica, reconfiguram o papel do radiologista e desafiam o conceito tradicional de prática médica. A relevância deste estudo reside justamente na necessidade de compreender a IA não como mera ferramenta técnica, mas como coautora de processos cognitivos e comunicativos que podem tanto ampliar quanto restringir a autonomia profissional.

Este ensaio propõe refletir, então, sobre essa transição, considerando que a verdadeira inovação tecnológica em saúde só se concretiza quando se alinha à ética do cuidado e ao valor centrado no paciente. Nesse contexto, discutir LLMs em radiologia é discutir o próprio futuro da medicina, um futuro em que eficiência e humanidade devem coexistir, não como polos opostos, mas como dimensões complementares de um mesmo compromisso com a vida.

O presente ensaio estrutura-se em quatro partes principais, além da introdução e das considerações finais. A introdução contextualiza a radiologia como campo pioneiro no uso da inteligência artificial e apresenta o problema central: como os Large Language Models (LLMs) podem gerar valor em saúde sem comprometer a humanização da prática médica. O referencial teórico discute o conceito de valor em saúde segundo Porter (2010) e Kaplan e Porter (2011), traça a trajetória da IA em radiologia e analisa os potenciais e limitações dos LLMs na medicina contemporânea. A discussão teórica aprofunda-se em quatro eixos: o suporte oferecido pelos LLMs ao radiologista; o valor que ultrapassa a eficiência técnica; os dilemas éticos e riscos da automação; e a redefinição do papel do radiologista como mediador entre inteligência humana e artificial.

2 REFERENCIAL TEÓRICO

2.1 VALOR EM SAÚDE: CONCEITO

O conceito de value-based healthcare, ou valor em saúde, representa uma mudança paradigmática no modo de compreender e organizar os sistemas de saúde. Michael Porter (2010, p. 2477) define claramente que:

> alcançar alto valor para os pacientes deve tornar-se o objetivo primordial da prestação de cuidados de saúde, sendo o valor definido como os resultados de saúde obtidos por dólar gasto[1].

Essa definição desloca o foco da quantidade de serviços oferecidos para os resultados efetivos alcançados, articulando eficiência, qualidade e sustentabilidade econômica em uma mesma equação.

Porter (2010, p. 2478) enfatiza ainda que o valor "deve ser medido em torno do paciente"[2], e não dos prestadores ou instituições (p. 2478). O autor critica os sistemas que medem desempenho a partir de indicadores de volume ou processos isolados, porque a medição de processos é útil, mas não substitui a mensuração de resultados e custos. A noção de valor, portanto, pressupõe uma integração

[1] No original: "achieving high value for patients must become the overarching goal of health care delivery, with value defined as the health outcomes achieved per dollar spent".
[2] No original: "should always be defined around the customer".

entre resultados clínicos e custos totais do ciclo de cuidado, tornando a eficiência um componente intrínseco da qualidade assistencial.

No mesmo sentido, Kaplan e Porter (2011, p. 47) argumentam que o grande problema dos sistemas de saúde está em "medir as coisas erradas da maneira errada[3]". Para eles, a raiz da crise de custos não reside apenas nas inovações tecnológicas ou na demografia, mas na quase completa falta de compreensão sobre quanto custa realmente fornecer o cuidado ao paciente. Essa ausência de mensuração precisa gera distorções econômicas, incentivos perversos e políticas ineficazes de contenção de custos.

A abordagem proposta por Kaplan e Porter combina mensuração precisa de custos e resultados, considerando o paciente e sua condição clínica como unidade básica de análise. Segundo os autores, "o objetivo adequado de qualquer sistema de saúde é melhorar o valor entregue aos pacientes[4]" (Kaplan; Porter, 2011, p. 49). Nessa perspectiva, o custo relevante é o total de recursos utilizados durante todo o ciclo de atendimento para uma condição médica específica, o que inclui profissionais, equipamentos, medicamentos e tempo de utilização dos serviços.

Do ponto de vista econômico, Porter (2010, p. 2) adverte que "a redução de custos sem levar em conta os resultados alcançados é perigosa e autodestrutiva"[5] (Porter, 2010, p. 2). Essa formulação reforça que valor não se confunde com economia, mas com eficiência clínica e humana. O aumento de valor pode ocorrer tanto pela obtenção de melhores desfechos com custo semelhante quanto pela manutenção de resultados equivalentes com menor custo. Em ambos os casos, é o equilíbrio entre o desempenho clínico e o uso racional dos recursos que define o verdadeiro avanço.

Por fim, a dimensão humana do value-based healthcare emerge da centralidade do paciente e da valorização de sua experiência de cuidado. Porter (2010) observa que "o valor deve ser medido pelos resultados alcançados, não pelo volume de serviços prestados"[6] (Porter, 2010, p. 2477), o que implica reconhecer que saúde não se resume a métricas financeiras, mas a ganhos efetivos de vida, funcionalidade e bem-estar. Ao integrar dimensões econômicas, clínicas e humanas, o modelo de valor em saúde propõe uma reforma ética e estrutural dos sistemas de cuidado, orientando-os não para o lucro ou para o controle de gastos, mas para a produção de resultados significativos e sustentáveis para as pessoas.

[3] No original: "measuring the wrong things the wrong way".
[4] No original: "the proper goal for any health care delivery system is to improve the value delivered to patients".
[5] No original: "cost reduction without regard to the outcomes achieved is dangerous and self-defeating".
[6] No original: "value should be measured by the outcomes achieved, not the volume of services delivered".

2.2 RADIOLOGIA E TECNOLOGIA: TRAJETÓRIA DO USO DE IA EM IMAGENS MÉDICAS

A trajetória da inteligência artificial (IA) na radiologia é marcada por um avanço progressivo que reflete a própria evolução das tecnologias de aprendizado profundo (deep learning) aplicadas à detecção, segmentação e classificação de imagens médicas. Kelly et al. (2022, p. 7999) destacam que:

> os algoritmos de aprendizado profundo demonstraram desempenho sólido em várias tarefas radiológicas, especialmente na detecção, segmentação e classificação de imagens[7].

Esses primeiros modelos marcaram o início de uma revolução na análise automatizada de imagens, substituindo abordagens baseadas em features manuais por redes neurais convolucionais capazes de aprender diretamente a partir dos dados.

O estudo de Kelly et al. (2022) também chama atenção para as limitações metodológicas das pesquisas iniciais. Segundo os autores, muitos estudos careciam de validação externa e utilizavam conjuntos de dados pequenos e homogêneos". Essa limitação impedia a generalização clínica dos resultados e levantava preocupações sobre vieses de amostragem e sobreajuste. Ainda assim, o campo avançou rapidamente, impulsionado pelo potencial das redes neurais em tarefas como detecção de nódulos pulmonares, hemorragias intracranianas e lesões mamográficas, etapas fundamentais na consolidação da IA como ferramenta diagnóstica de apoio ao radiologista.

A segunda fase dessa trajetória é analisada por Najjar (2023), que descrevem a integração gradual da IA ao fluxo de trabalho clínico. Os autores observam que a IA passou de protótipos de pesquisa para ferramentas clínicas que auxiliam radiologistas na detecção e na triagem. Esse movimento consolidou o papel das ferramentas de secondary reading, nas quais o sistema atua como um segundo leitor, oferecendo uma verificação adicional que aumenta a sensibilidade diagnóstica e reduz erros de omissão. Najjar (2023) ressaltam, a adoção continua desigual devido à disrupção dos fluxos de trabalho, desafios regulatórios e ceticismo quanto à confiabilidade dos algoritmos.

Na etapa mais recente, Wenderott et al. (2024) oferecem uma análise quantitativa do impacto da IA na eficiência operacional. Em uma metanálise envolvendo 48 estudos, os autores verificaram 33 estudos mediram o tempo de execução de tarefas, com 67% relatando reduções.

Apesar disso, eles advertem que três metanálises separadas de 12 estudos não mostraram efeitos significativos após a implementação da IA. Tais resultados indicam que os ganhos operacionais mensuráveis ainda são heterogêneos e fortemente dependentes do contexto clínico, do desenho metodológico e da forma de integração ao fluxo de trabalho (Wenderott et al., 2024).

[7] No original: "deep learning algorithms have demonstrated strong performance across various radiological tasks, particularly in image detection, segmentation, and classification".

Ainda de acordo com Wenderott et al. (2024), a IA atuou mais frequentemente como um segundo leitor em tarefas de detecção. Esse modelo de uso, o de "leitor secundário", confirma a tendência de coexistência entre humano e máquina, em que a IA não substitui o radiologista, mas o auxilia a priorizar casos críticos, reduzir tempo de leitura e aumentar a acurácia diagnóstica. A revisão também observou a adoção de fluxos híbridos, como sistemas de triagem automatizada e reorganização de listas de trabalho, que refletem o amadurecimento da IA como componente efetivo de eficiência clínica.

Hoje, a chegada dos Large Language Models (LLMs) representa uma nova camada dessa trajetória tecnológica. Enquanto os algoritmos de deep learning anteriores lidavam essencialmente com pixels e padrões visuais, os LLMs ampliam o escopo da IA ao permitir a interpretação textual, a integração multi-modal e a interação conversacional com o profissional. Como apontam Najjar (2023), a IA na radiologia está avançando para sistemas integrativos, capazes de compreender tanto imagens quanto narrativas clínicas. Essa convergência inaugura uma nova etapa: a radiologia aumentada por linguagem, em que a IA deixa de ser apenas uma ferramenta de processamento visual e passa a atuar como mediadora cognitiva entre imagem, texto e decisão clínica.

2.3 LLMs NA SAÚDE: POTENCIAIS E LIMITAÇÕES

A introdução dos Large Language Models (LLMs) na área da saúde tem despertado entusiasmo e cautela em igual medida. Segundo D'Antonoli et al. (2024, p. 86):

> Na verdade, os LLMs podem ser integrados aos softwares e sistemas de radiologia existentes para auxiliar os radiologistas de várias maneiras. Por exemplo, eles podem servir como uma interface de linguagem natural para diversas ferramentas radiológicas atualmente em uso. Os radiologistas podem interagir com o sistema utilizando consultas em linguagem simples, o que torna mais fácil recuperar dados de pacientes, relatórios e imagens[8].

Essa capacidade de processar linguagem natural em ambientes complexos representa um avanço considerável sobre os sistemas baseados em regras, favorecendo padronização e eficiência em fluxos clínicos.

Além disso, Bahl et al. (2024) observam que o ChatGPT e outros grandes modelos de linguagem demonstraram potencial na redação de laudos radiológicos e na sumarização de achados de imagem, mas seus resultados exigem revisão humana cuidadosa antes do uso clínico. A advertência reforça que, embora os LLMs melhorem a produtividade e a acessibilidade do conhecimento médico,

[8] No original: "In fact, LLMs can be integrated with existing radiology software and systems to assist radiologists in various ways. For example, they can serve as a natural language interface to several radiology tools currently in use. Radiologists can interact with the system using plain language queries, making it easier to retrieve patient data, reports, and images".

ainda há barreiras éticas e técnicas que demandam supervisão profissional, principalmente no contexto de relatórios clínicos sensíveis.

Do ponto de vista da integração ampla no setor da saúde, Nazi e Peng (2024, p. 2) enfatizam que "os LLMs atuam como um multiplicador de força, auxiliando profissionais de saúde que enfrentam sobrecarga de informação"[9]. Essa capacidade de sintetizar dados heterogêneos, desde literatura médica até registros de pacientes, amplia a acessibilidade do conhecimento e reduz o tempo gasto em tarefas administrativas. Ainda segundo os autores (Nazi; Peneg, 2024, p. 01) "o imenso valor dos LLMs reside em sua capacidade de processar e sintetizar volumes colossais de literatura médica, prontuários de pacientes e pesquisas clínicas"[10], apontando o potencial transformador dessas ferramentas na gestão e circulação do saber médico.

Wang e Zhang (2024, p. 299) corroboram esse panorama ao afirmar que:

> os LLMs têm o potencial de facilitar a comunicação entre profissionais de saúde, pacientes e familiares, agilizar a coleta e análise de dados clínicos e auxiliar no desenvolvimento de planos cirúrgicos[11].

Os autores também destacam que a tradução automática e a geração de registros eletrônicos de saúde (EHRs) baseadas em linguagem natural representam dimensões centrais de acessibilidade e padronização, permitindo que informações clínicas sejam compartilhadas de maneira mais inclusiva e eficiente.

No entanto, as limitações permanecem significativas. Nazi e Peng (2024) alertam que a introdução dos LLMs no domínio altamente sensível e regulamentado da saúde exige consideração cuidadosa de ética, privacidade e segurança.

Do mesmo modo, Wang e Zhang (2024, p. 299) identificam "segurança dos dados, informações imprecisas, equidade e viés, plágio, direitos autorais e responsabilidade[12]", como desafios que ainda limitam o uso clínico confiável desses sistemas. A complexidade semântica e cultural dos textos médicos exige que os modelos sejam continuamente refinados por meio de fine-tuning em bases específicas, evitando erros de interpretação potencialmente perigosos.

Por fim, D'Antonoli et al. (2024) sintetizam o horizonte emergente ao afirmar que os LLMs podem transformar a prática radiológica ao ampliar a acessibilidade, possibilitar suporte clínico em

[9] No original: "LLMs act as a powerful force multiplier, aiding healthcare professionals struggling with information overload".
[10] No original: "the immense value of LLMs lies in their ability to process and synthesize colossal volumes of medical literature, patient records, and clinical research"
[11] No original: "LLMs have the potential to facilitate communication among healthcare professionals, patients, and their families, streamline the collection and analysis of patient health data, and assist in the development of surgical plans"
[12] No original: "data security, inaccurate information, fairness and bias, plagiarism, copyrights, and accountability"

tempo real e aprimorar a comunicação entre médicos e pacientes. No entanto, como reforça Bahl et al. (2024), a chave para o sucesso reside na implementação adequada, na supervisão ética e na avaliação contínua das saídas da IA. Assim, os LLMs configuram-se não apenas como ferramentas técnicas, mas como mediadores linguísticos e epistemológicos que desafiam a fronteira entre automação e discernimento humano.

3 DISCUSSÃO TEÓRICA

3.1 LLMs COMO SUPORTE AO RADIOLOGISTA

Os Large Language Models (LLMs) vêm se consolidando como instrumentos de apoio direto à prática radiológica, sobretudo em tarefas de geração de laudos, padronização de relatórios e segunda opinião diagnóstica. Como observam Liu et al. (2024, p. 1) sobre um dos LLMs:

> O Radiology-GPT demonstra desempenho superior em comparação com os modelos de linguagem gerais [...] e apresenta significativa versatilidade no diagnóstico radiológico, na pesquisa e na comunicação[13].

Possível, então, dizem os autores, que o modelo aprenda o vínculo entre observações e interpretações, simulando a estrutura cognitiva dos radiologistas. Esse processo automatiza parte do raciocínio descritivo, sem eliminar a necessidade do juízo humano, o que reduz a sobrecarga documental e melhora a consistência de terminologias.

Além do suporte linguístico, tais modelos oferecem auxílio interpretativo contextual. Ullah et al. (2024) apontam que o ChatGPT pode ser combinado com modelos de visão computacional para ampliar sua utilidade na patologia computacional, e sistemas como o ChatCAD já combinam o ChatGPT com um classificador de doenças e um detector de lesões para diagnosticar imagens radiológicas.

Essa integração multimodal, linguagem e imagem, configura um novo paradigma de clinical decision support, em que os relatórios gerados automaticamente dialogam com os achados visuais, fornecendo ao especialista uma síntese prévia de hipóteses. A consequência imediata é a economia de tempo e a possibilidade de o radiologista concentrar-se em casos de maior complexidade clínica (D'Antonoli et al., 2024).

Em termos operacionais, os mesmos autores (D'Antonoli et al., 2024) confirmam que os LLMs podem integrar-se aos sistemas de informação radiológica, PACS e prontuários eletrônicos (EMRs)

[13] No original: "Radiology-GPT demonstrates superior performance compared to general language models [...] and exhibits significant versatility in radiological diagnosis, research, and communication".

para automatizar tarefas repetitivas, como geração de relatórios, sumarização de dados e documentação clínica, o que aumenta a acessibilidade, possibilita suporte à decisão em tempo real e melhora a comunicação entre médicos e pacientes.

Essa automação parcial transforma o LLM em uma camada linguística de mediação entre sistemas e profissionais, reduzindo redundâncias e elevando a qualidade da informação diagnóstica. Desse modo, o modelo não substitui o olhar do radiologista, mas o amplia, atuando como coadjuvante na organização do conhecimento clínico.

3.2 VALOR PARA ALÉM DA EFICIÊNCIA

Os ganhos proporcionados pelos LLMs ultrapassam a mera eficiência operacional. A pesquisa de Nazi e Peng (2024) ressalta que as LLMs ampliam a democratização do acesso à informação médica, pois profissionais de regiões distintas podem usufruir do mesmo acervo sintético e continuamente atualizado, reduzindo desigualdades no cuidado. Assim, a tecnologia introduz um vetor de equidade ao disponibilizar conhecimento médico em tempo real, independentemente da localização geográfica.

A humanização do diagnóstico emerge quando os LLMs passam a traduzir achados técnicos em linguagem acessível. Wang e Zhang (2024) destacam que essa mediação linguística contribui para que relatórios radiológicos possam ser explicados em termos compreensíveis ao paciente, o que aumenta a transparência e reforça a confiança na relação médico-paciente. Assim, o valor em saúde não se limita à produtividade, mas envolve a construção de sentido compartilhado e compreensão mútua no processo diagnóstico.

A notícia de Sabet (2023)[14] sobre o modelo CXR Lung-Risk ilustra esse potencial social. A ferramenta “abre caminho para a triagem oportunista de não fumantes com alto risco de câncer de pulmão, utilizando radiografias de tórax já existentes”[15], identificando “28% dos não fumantes como estando em alto risco”[16]. Ao permitir rastrear perfis até então invisíveis às diretrizes tradicionais, a IA amplia o alcance do cuidado preventivo. Essa capacidade de triagem automatizada e inclusiva representa o que Porter (2010) denomina “valor em saúde”: resultados clínicos relevantes obtidos de modo eficiente e equitativo.

[14] “This AI model can tell if you're at high risk of lung cancer by analyzing a single X-ray scan”. In: Live Science, 2023. Disponível em: https://www.livescience.com/technology/artificial-intelli-gence/this-ai-model-can-tell-if-youre-at-high-risk-of-lung-cancer-by-analyzing-a-single-x-ray-scan Acesso em 31 de out. 2025.
[15] No original: “Opens the door for opportunistic screening for never-smokers at high risk of lung cancer, using existing chest X-rays”.
[16] No original: “28% of non-smokers as being at high risk”.

3.3 DILEMAS E RISCOS

Apesar dos benefícios, os riscos associados aos LLMs em radiologia são substanciais. Ullah et al. (2024) alertam para viéses nos dados de treinamento que representam um risco de perpetuar disparidades e imprecisões nos diagnósticos e para questões éticas incluindo privacidade do paciente, segurança dos dados e uso responsável da IA.

Tais questões envolvem o dilema da responsabilidade: quem responde por um erro gerado por um algoritmo? Também exigem novas formas de governança ética e regulatória. O estudo enfatiza ainda que a integração acrítica de modelos de linguagem pode afetar autonomia e capacidade de tomada de decisão dos profissionais de saúde gerando dependência cognitiva e desvalorização da expertise humana (Ullah et al., 2024)

Cross et al. (2024, p. 1) aprofundam esse debate ao afirmar que: “A inteligência artificial médica enviesada pode levar a decisões clínicas abaixo do padrão e à perpetuação e intensificação de desigualdades históricas na área da saúde”[17].

Além dos vieses, a privacidade e a segurança dos dados de imagem representam desafios críticos. Kao e Kao (2025) discutem que o manuseio de prontuários e imagens médicas em ambientes de aprendizado de máquina precisa respeitar o princípio da confidencialidade, evitando transferências para servidores externos sem consentimento explícito. Esse cuidado converge com a defesa de Liu et al. (2024) pela criação de modelos “localized and HIPAA-compliant” que possam operar dentro das instituições de saúde sem expor informações sensíveis.

Assim, a inovação só se sustenta se ancorada em uma ética da responsabilidade coletiva, que envolva desenvolvedores, médicos e reguladores.

3.4 REDEFINIÇÃO DO PAPEL DO RADIOLOGISTA

A emergência dos LLMs inaugura uma reconfiguração do papel do radiologista, deslocando-o de executor técnico para intérprete crítico de sistemas inteligentes. Liu et al. (2024, p. 2) observam que os modelos gerativos “

> pode fornecer percepções contextuais e respostas de forma conversacional, imitando uma interação semelhante à humana e, assim, aprimorando a usabilidade desses modelos em um ambiente clínico[18].

[17] No original: “biased medical AI can lead to substandard clinical decisions and the perpetuation and exacerbation of longstanding healthcare disparities”.
[18] No original: “can provide contextual insights and responses in a conversational manner, mi-micking a human-like interaction, and hence enhancing the usability of these models in a clinical setting”.

Isso significa que o profissional deixa de ser mero elaborador de relatórios e passa a atuar como curador de sentidos, verificando, corrigindo e contextualizando as saídas algorítmicas. O resultado é uma prática mais reflexiva, na qual a interação com a máquina estimula o julgamento clínico, em vez de substituí-lo. Contudo, esse novo cenário acarreta o chamado "paradoxo da automação", em que o aumento da dependência tecnológica pode simultaneamente ameaçar e empoderar o profissional. Ullah et al. (2024) alertam para o risco de excesso de confiança e dependência podendo levar à redução do pensamento crítico ou da tomada de decisão independente por parte dos profissionais de saúde.

A função do radiologista, portanto, desloca-se para a supervisão interpretativa, onde a confiabilidade do sistema depende da capacidade humana de reconhecer limites e corrigir desvios. Tal equilíbrio é essencial para evitar a alienação cognitiva que o uso acrítico de ferramentas automatizadas pode provocar (Ullah et al., 2024).

Em última instância, a redefinição do papel do radiologista exige formação contínua e letramento digital clínico. Wang e Zhang (2024) defendem que os LLMs provavelmente se tornarão parte integrante da educação em saúde e da documentação clínica, enquanto D'Antonoli et al. (2024) acrescentam que a chave para o sucesso reside na implementação adequada, na supervisão ética e na avaliação contínua das saídas da IA.

Assim, o radiologista contemporâneo torna-se um mediador entre a inteligência humana e a artificial, atuando em um espaço de cooperação crítica. O empoderamento, nesse contexto, não decorre da substituição do profissional pela máquina, mas da ampliação de suas capacidades cognitivas e comunicativas diante de sistemas cada vez mais autônomos.

4 CONSIDERAÇÕES FINAIS

As considerações finais deste ensaio apontam que os Large Language Models (LLMs) representam uma inflexão decisiva na história da radiologia, não apenas pela ampliação da eficiência diagnóstica, mas pela possibilidade de instaurar uma nova gramática da prática médica, uma prática em que imagem, linguagem e decisão clínica se integram de modo inédito.

O percurso teórico e empírico discutido demonstra que o verdadeiro valor em saúde, conforme Porter (2010) e Kaplan e Porter (2011), não se limita a ganhos operacionais, mas envolve a produção de resultados sustentáveis e centrados no paciente. Assim, os LLMs, quando aplicados de forma ética, transparente e supervisionada, podem fortalecer a capacidade do radiologista de oferecer diagnósticos mais contextualizados, equitativos e humanizados, reafirmando o princípio de que a tecnologia deve servir à vida, e não o inverso.

Todavia, a introdução dos LLMs evidencia tensões inescapáveis entre automação e autonomia, eficiência e empatia, objetividade e julgamento clínico. Como enfatizam D'Antonoli et al. (2024) e Wang e Zhang (2024), a presença crescente da IA na medicina exige um novo tipo de profissional, crítico, ético e digitalmente letrado, capaz de reconhecer tanto as potencialidades quanto as limitações das ferramentas que utiliza.

A dependência excessiva pode gerar riscos de desumanização e de viés algorítmico, mas, quando equilibrada pela mediação interpretativa do radiologista, a tecnologia torna-se um vetor de emancipação cognitiva e cooperativa. O desafio, portanto, é conceber a IA como parceira hermenêutica, que amplia as fronteiras do diagnóstico sem dissolver a singularidade do olhar humano.

Conclui-se que o futuro da radiologia dependerá menos da capacidade técnica das máquinas e mais da disposição ética e formativa dos profissionais em integrá-las de modo crítico e responsável. A geração de valor em saúde será tanto maior quanto mais conseguir aliar precisão e sensibilidade, automatização e cuidado, ciência e humanidade. Nesse sentido, os LLMs só realizarão plenamente seu potencial transformador se forem incorporados a um projeto de medicina centrada na pessoa, orientado pela responsabilidade coletiva e pela permanente reflexão sobre o que significa cuidar em uma era de inteligências compartilhadas.

REFERÊNCIAS

Bahl M, Balthazar P, Davis MA, Makary MS, Tirumani SH, Whitlow CT. (2024). ChatGPT and Large Language Models in Radiology: Perspectives From the Field. *AJR Am J Roentgenol*. Oct;223(4).

Cross JL, Choma MA, Onofrey JA. (2024). Bias in medical AI: Implications for clinical decision-making. *PLOS Digit Health*. Nov 7;3(11).

D'Antonoli T, Stanzione A, Bluethgen C, Vernuccio F, Ugga L, Klontzas ME, Cuocolo R, Cannella R, Koçak B. (2024). Large language models in radio-logy: fundamentals, applications, ethical considerations, risks, and future di-rections. *Diagn Interv Radiol*. Mar 6;30(2):80-90.

Kao, J. Kao, HT. (2025). Large Language Models in radiology: A technical and clinical perspective, *European Journal of Radiology Artificial Intelligence*, 2.

Kaplan RS, Porter ME. (2011). How to Solve the Cost Crisis in Health Care. *Har-vard Business Review*, September 2011, 47-52.

Kelly BS, Judge C, Bollard SM, Clifford SM, Healy GM, Aziz A, Mathur P, Islam S, Yeom KW, Lawlor A, Killeen RP. (2022). Radiology artificial intelligence: a systematic review and evaluation of methods (RAISE). *Eur Radiol*. Nov;32(11):7998-8007.

Najjar, R. (2023). Redefining Radiology: A Review of Artificial Intelligence Integra-tion in Medical Imaging. Diagnostics, 13, 2760.

Nazi, ZA, Peng, W. (2024). Large Language Models in Healthcare and Medical Domain: A Review. *Informatics*, 11(3), 57.

Porter, ME (2010). What is Value in Health Care? *The New England Journal of Medicine*, 363(26), 2477-2481.

Saber, A. (2023). This AI model can tell if you're at high risk of lung cancer by analyzing a single X-ray scan. *Live Science*, 2023. Disponível em: https://www.livescience.com/technology/artificial-intelligence/this-ai-model-can-tell-if-youre-at-high-risk-of-lung-cancer-by-analyzing-a-single-x-ray- scan Recuperado em 31 de out. 2025.

Wenderott K, Krups J, Zaruchas F, Weigl M. (2024) Effects of artificial intelligence implementation on efficiency in medical imaging-a systematic literature re-view and meta-analysis. *NPJ Digit Med*. Sep 30;7(1):265.

Wang, D., Zhang, S. (2024) Large language models in medical and healthcare fields: applications, advances, and challenges. *Artif Intell Rev* 57, 299.