

Inteligência Artificial na Ultrassonografia de Carótidas: Onde estamos e para onde vamos?

Artificial Intelligence in Carotid Ultrasonography: Current Status and Future Directions

Gustavo Paglioli Dannenhauer,¹ Simone Nascimento dos Santos,² Ana Claudia Gomes Pereira Petisco,³ Claudia Maria Vilas Freire,⁴ Ana Cristina Lopes Albricker,⁵ Fanilda Souto Barros⁶

Clínica Biocor,¹ Caxias do Sul, RS – Brasil

Eccos Diagnóstico Cardiovascular Avançado,² Brasília, DF – Brasil

Instituto Dante Pazzanese de Cardiologia,³ São Paulo, SP – Brasil

Universidade Federal de Minas Gerais (UFMG),⁴ Belo Horizonte, MG – Brasil

IMEDE – Instituto de Ultrassonografia, CEU Diagnósticos, Faculdade de Medicina UNIBH,⁵ Belo Horizonte, MG – Brasil

Instituto Fanilda Barros,⁶ Vitória, ES – Brasil

Resumo

A avaliação carotídea evoluiu de uma abordagem centrada no grau de estenose para uma análise mais abrangente, incluindo a carga de placa, morfologia, composição e vulnerabilidade. Algoritmos de inteligência artificial (IA) têm sido aplicados à detecção automática de placas, segmentação de imagens, classificação de estabilidade, extração de atributos radiômicos e predição de eventos isquêmicos. Quando associados a técnicas avançadas de imagem, esses modelos podem ampliar a reprodutibilidade, reduzir a dependência do operador e revelar padrões quantitativos não reconhecíveis pela avaliação visual convencional. Assim, este estudo teve por objetivo revisar as aplicações atuais da IA na ultrassonografia de carótidas e suas perspectivas futuras, com uma revisão narrativa baseada em estudos recentes sobre aprendizado de máquina, aprendizado profundo, radiômica e integração com modalidades ultrassonográficas avançadas, abrangendo contraste, elastografia, ultrassom tridimensional (3D), técnicas de microfluxo e ultrassonografia ultrarrápida. Apesar dos resultados promissores, ainda persistem desafios relacionados à padronização das imagens, validação externa, explicabilidade dos modelos e demonstração de impacto clínico prospectivo. Ainda assim, a IA demonstra ter potencial para transformar a ultrassonografia carotídea em ferramenta multiparamétrica de medicina personalizada. Sua incorporação clínica dependerá de validação robusta, integração ao fluxo assistencial e comprovação de valor incremental sobre o exame convencional.

Introdução

A aterosclerose carotídea constitui um importante marcador de risco cardiovascular e cerebrovascular, tradicionalmente

avaliado pela ultrassonografia com foco predominante no grau de estenose luminal. Esse paradigma foi consolidado a partir de estudos clássicos que embasaram decisões terapêuticas principalmente em pacientes sintomáticos. No entanto, os avanços no conhecimento sobre a biologia da placa mostraram que a estenose, isoladamente, não explica todo o risco clínico, sobretudo em indivíduos assintomáticos ou com lesões não obstrutivas.¹⁻⁴

Nas últimas décadas, tornou-se cada vez mais evidente que a simples presença da placa, sua carga aterosclerótica e suas características morfológicas e composicionais acrescentavam informação prognóstica relevante além dos escores clínicos tradicionais. Em coortes contemporâneas, placas carotídeas pequenas, inclusive com estenoses menores que 50%, foram associadas ao aumento progressivo do risco de eventos ateroscleróticos, particularmente quando bilaterais ou acompanhadas de acometimento femoral, reforçando o conceito de aterosclerose subclínica sistêmica e multivascular.² Em prevenção primária, a quantificação da carga de placa mostrou maior valor preditivo do que a espessura médio-intimal isolada, além de impactar condutas clínicas, como intensificação do uso de estatinas.⁵ Esses achados sustentam a transição de um modelo centrado apenas na hemodinâmica para outro mais abrangente, voltado à caracterização da placa e à estratificação individualizada de risco.^{1-3,6,7}

Nessa discussão, a ultrassonografia de carótidas ocupa posição privilegiada. Trata-se de método amplamente disponível, isento de radiação ionizante e capaz de fornecer informações anatômicas, hemodinâmicas e características teciduais. Além da identificação da placa, o exame pode descrever espessura máxima, ecogenicidade, irregularidade de superfície, ulceração, carga aterosclerótica e, com técnicas mais recentes, neovascularização intraplaca, propriedades biomecânicas e volume tridimensional (3D).^{1,3} Diretrizes e documentos de consenso enfatizam o papel da placa carotídea como biomarcador de risco cardiovascular e a necessidade de incorporar características além da estenose na avaliação clínica.^{3,4,8,9} De forma convergente, propostas padronizadas, como o Carotid Plaque-RADS, surgem como expressão de uma abordagem mais integrada da vulnerabilidade da placa e do risco de acidente vascular cerebral (AVC).^{10,11}

Apesar desse potencial, a ultrassonografia carotídea permanece parcialmente limitada por dependência do operador, variabilidade de aquisição, heterogeneidade entre

Palavras-chave

Ultrassonografia das Artérias Carótidas; Inteligência Artificial; Placa Aterosclerótica

Correspondência: Gustavo Paglioli Dannenhauer •

Rua Sinimbu, 2211. CEP: 95020-520. Caxias do Sul, RS – Brasil


E-mail: gustavodannenhauer@gmail.com

Artigo recebido em 05/07/2026; revisado em 07/07/2026; aceito em 07/07/2026

Editor responsável pela revisão: Marcelo Tavares

DOI: <https://doi.org/10.36660/abcimg.20260089>

Figura Central: Inteligência Artificial na Ultrassonografia de Carótidas: Onde estamos e para onde vamos?



Arq Bras Cardiol: Imagem cardiovasc. 2026; 39(3):e20260089

equipamentos e subjetividade na interpretação de fenótipos complexos de placa. Características relevantes como núcleo lipídico-necrótico, hemorragia intraplaca, neovascularização, inflamação e fragilidade da capa fibrosa podem ser inferidas por sinais ultrassonográficos, mas nem sempre são detectadas ou quantificadas de modo reprodutível.^{1,10,12} É justamente diante dessa lacuna que a inteligência artificial (IA) emerge como ferramenta promissora.

A aplicação de IA na ultrassonografia de carótidas tem crescido rapidamente nos últimos anos, abrangendo desde a detecção automática de placa e segmentação do lúmen e da parede até a classificação de vulnerabilidade, predição de eventos e apoio ao fluxo de trabalho clínico. Os modelos baseados em *machine learning* (aprendizado de máquina) e *deep learning* (aprendizado profundo) têm demonstrado capacidade de extrair padrões texturais e morfológicos invisíveis à inspeção visual convencional, com potencial para reduzir variabilidade interobservador, acelerar a análise e ampliar o valor prognóstico do exame.¹³⁻¹⁶ Em paralelo, modalidades avançadas como contraste ultrassonográfico (CEUS), elastografia, imagem de fluxo microvascular, ultrassonografia 3D e super-resolução oferecem novos biomarcadores que podem ser integrados à IA em abordagens multiparamétricas.¹⁷⁻²¹

Diante desse panorama, esta revisão discute as aplicações atuais da IA na ultrassonografia de carótidas e suas perspectivas futuras, com ênfase em detecção e quantificação

da placa, caracterização de vulnerabilidade, integração com modalidades avançadas de imagem e potencial impacto na estratificação de risco e na prática clínica (Figura Central). Processo de extração de dados da imagem fundamental na ultrassonografia de carótidas através da radiômica (Figura A). Integração e avaliação multimodal da placa carotídea por meio de IA (Figura B). Tipos de desfechos finais em estudos atuais usando IA (Figura C).

Fundamentos da IA aplicados ao ultrassom carotídeo

A aplicação da IA ao ultrassom carotídeo depende da conversão de imagens em informação analisável por algoritmos. Em termos práticos, isso significa transformar um exame bidimensional, dinâmico e operador-dependente em um conjunto estruturado de dados capaz de sustentar tarefas como detecção de placa, segmentação anatômica, caracterização tecidual e estratificação de risco, auxiliando, assim, na tomada de decisão clínica.^{13,14,22,23}

De modo geral, a IA aplicada à imagem médica pode ser compreendida em três níveis principais. O primeiro é o aprendizado de máquina convencional, no qual atributos previamente definidos são extraídos da imagem e então utilizados por algoritmos para classificação ou predição. O segundo é o aprendizado profundo, em que redes neurais aprendem diretamente dos pixels captados em imagens, identificando padrões complexos sem depender, necessariamente, de variáveis manualmente selecionadas.

O terceiro é a integração entre ambos, frequentemente combinando segmentação automatizada, extração de descritores quantitativos e modelos clínico-imagiológicos compostos.^{13,14,23,24}

No ultrassom carotídeo, esse processo começa com a aquisição da imagem, que é o pilar para a extração dos dados de entrada, e nenhum modelo é capaz de superar limitações graves na qualidade desses dados. Fatores como ganho inadequado, profundidade excessiva, janela ruim, sombra acústica intensa, artefatos de movimento, baixa padronização entre aparelhos ou diferenças de protocolos podem afetar decisivamente o desempenho dos algoritmos. Essa dependência ajuda a explicar por que a padronização técnica e a harmonização de imagens se tornaram temas centrais no desenvolvimento de modelos robustos.^{23,25,26}

Após a aquisição, muitos fluxos de processamento de IA passam pela segmentação, isto é, a identificação automática ou semiautomática das estruturas de interesse, como lúmen, complexo íntima-média, parede arterial e placa aterosclerótica. Essa etapa é crucial porque delimita a região da qual serão extraídas as informações quantitativas. Quando a segmentação é imprecisa, o modelo passa a aprender ruídos, bordas mal definidas ou regiões não representativas.^{22,23,25-27}

Uma vez delimitada a região de interesse, a IA pode trabalhar de diferentes formas. Nos modelos clássicos, a imagem é convertida em um conjunto de atributos, incluindo medidas simples — como a espessura, área da placa ou ecogenicidade média — e descritores mais sofisticados de textura, heterogeneidade, borda e distribuição de intensidades. É nesse contexto que a radiômica se insere. Ela consiste na conversão da imagem em uma matriz rica de variáveis quantitativas, muitas delas não perceptíveis ao olho humano, capazes de gerar e alimentar classificadores ou modelos preditivos.^{22,23,26,28,29}

Essa lógica é especialmente relevante na ultrassonografia carotídea, porque a vulnerabilidade da placa não depende apenas do grau de estenose ou da sua impressão visual global, mas também de características microestruturais relacionadas à composição lipídica, fibrose, calcificação, hemorragia intraplaca, inflamação e neovascularização. A radiômica, portanto, pode ser entendida como uma ponte entre a imagem convencional e a fenotipagem biológica da lesão.^{22,23,26,28}

Já nos modelos de aprendizado profundo, em especial nas redes neurais convolucionais, a própria rede aprende representações internas da imagem a partir de sucessivas camadas de processamento. Em vez de o pesquisador definir quais atributos importam, o modelo identifica padrões hierárquicos por conta própria, desde bordas e contrastes básicos até formas, texturas e arranjos espaciais associados a estabilidade ou vulnerabilidade da placa.^{13,15,29-32}

Além disso, a construção de um bom modelo depende de desenho metodológico rigoroso. Em termos simplificados, os dados precisam ser divididos em conjuntos de treinamento, validação e teste. Quando o modelo aprende excessivamente os detalhes específicos da amostra de

treinamento e perde capacidade de generalização, ocorre o sobreajuste, problema ainda frequente em bases pequenas, monocêntricas ou muito homogêneas.^{16,23,26}

Outro conceito central é a validação externa. Um modelo que funciona bem em imagens adquiridas em um único centro, com um único equipamento e uma única população pode falhar quando aplicado a outro cenário. Por isso, o verdadeiro valor clínico da IA não se relaciona apenas com altas áreas sob a curva (AUC) dentro do banco original, mas com a sua capacidade de manter desempenho em populações independentes e em ambientes reais.^{13,16,26}

Além da acurácia, entram em jogo métricas como sensibilidade, especificidade, AUC, calibração e utilidade clínica. Mesmo quando é capaz de discriminar adequadamente placas vulneráveis, um modelo pode não ser útil se não for calibrado de forma correta, gerar muitos falsos positivos ou não alterar condutas. Por essa razão, trabalhos mais maduros tendem a integrar a IA com variáveis clínicas, laboratoriais e hemodinâmicas, em vez de tratá-la como ferramenta isolada, caracterizando uma abordagem de IA multimodal.^{29,31,33}

Por fim, há o fator da explicabilidade. Em um exame tão ligado à prática visual do especialista, modelos de “caixa-preta” tendem a gerar resistência. Portanto, a utilização de estratégias de interpretação, como mapas de atenção e análise de importância de variáveis, ajuda a mostrar quais regiões da imagem ou quais padrões contribuíram para determinada classificação.^{14,26}

Aplicações atuais da IA na ultrassonografia de carótidas

As aplicações atuais da IA na ultrassonografia de carótidas se concentram em ampliar a capacidade do exame de identificar, quantificar e interpretar sinais de aterosclerose de forma mais objetiva, rápida e reprodutível.^{1,16,24}

Uma das aplicações mais intuitivas da IA é a detecção automática de placa aterosclerótica. Modelos recentes baseados em aprendizado profundo têm mostrado desempenho elevado para identificar a presença de placa em imagens modo B, inclusive em contextos multicêntricos. He et al.,¹³ por exemplo, demonstraram que um algoritmo de aprendizado profundo foi capaz não apenas de identificar placas carotídeas, mas também de diferenciá-las segundo a estabilidade. Em escala populacional, Omarov et al.³¹ mostraram que a detecção automatizada de placas em ultrassonografia carotídea pode informar predição de risco cardiovascular e até contribuir para a associação com determinantes genéticos da aterosclerose. Em uma direção mais voltada à prática clínica, modelos em tempo real baseados em arquiteturas como YOLO (*You Only Look Once*) também têm sido explorados no intuito de realizar um reconhecimento instantâneo das placas em imagens ou vídeos, sugerindo potencial para triagem assistida e redução da variabilidade entre operadores.³⁰

Contudo, a detecção isolada é apenas o primeiro passo. Para que a imagem possa ser analisada quantitativamente, a IA precisa definir com precisão onde está a lesão e quais são os seus limites. Essa etapa é crítica porque medidas como espessura máxima, área e carga de placa

dependem de segmentação confiável, e grande parte dos fluxos de classificação e modelagem quantitativa depende de regiões de interesse bem definidas.^{22,25} Uma vez que a placa é identificada e segmentada, a IA pode ser aplicada à quantificação da carga aterosclerótica. Aqui, o objetivo é que a automatização das medições das lesões contribua para que esse processo seja mais eficiente, o qual, manualmente, é mais demorado ou menos reprodutível.

A partir do reconhecimento da placa, estudos com fluxos de processamentos passaram a abordar a diferenciação entre placa estável e placa vulnerável, sendo essa, talvez, a área em que a IA mais diretamente tente traduzir a fisiopatologia em decisão clínica. A ideia não é apenas reconhecer a presença da lesão, mas inferir se ela contém características associadas a maior risco de ruptura, embolização e eventos.¹³⁻¹⁵

É nesse esforço que a radiômica assume papel particularmente relevante como aplicação clínica da IA. Em vez de depender apenas de impressão visual ou de descritores morfológicos convencionais, a radiômica permite transformar a imagem em uma assinatura quantitativa de textura, heterogeneidade e organização interna da placa. Song et al.²² mostraram que a combinação de segmentação assistida por IA e radiômica ultrassonográfica pode discriminar placas estáveis e vulneráveis com desempenho relevante. Nessa mesma linha, Jadoon et al.²⁸ ampliaram essa lógica ao explorar extração de características radiômicas não apenas do modo B, mas também de sinais de radiofrequência da parede carotídea. De forma complementar, Zhao et al.³⁴ mostraram que abordagens radiômicas aplicadas ao microambiente perivascular também podem carregar informação relevante para a identificação de placas sintomáticas.

Essa aplicação se estende naturalmente à predição de eventos e à estratificação de risco. Estudos recentes indicam que a IA pode combinar variáveis ultrassonográficas com dados clínicos para prever riscos de eventos cerebrovasculares, como o AVC isquêmico e progressão clínica. Song et al.²² e Jin et al.³² evidenciaram que modelos baseados em imagem ultrassonográfica, especialmente quando integrados ao CEUS, podem aprimorar a predição de placas vulneráveis associadas a maior risco de AVC agudo. Em casos de pacientes com diabetes tipo 2, Liu et al.²⁹ construíram um nomograma radiômico baseado em ultrassom carotídeo para prever riscos de AVC isquêmico, observando desempenho superior quando o escore radiômico foi combinado com variáveis clínicas. Chen et al.³⁵ também exploraram modelagem preditiva baseada em indicadores ultrassonográficos de neovascularização intraplaca. Adicionalmente, Gao et al.³⁶ propuseram um modelo profundo automatizado para estratificação de risco de AVC em placas carotídeas.

Recentemente, Jiang et al.³⁷ descreveram o sistema UltraBot, um robô de aprendizado em larga escala que, talvez, seja o exemplo mais emblemático dessa tendência da automação do exame. Aqui, vemos um sistema integrado em que um braço robótico mimetiza movimentos, pressão de transdutor, angulações de janela e, depois, analisa imagens e reconhece padrões, tudo de forma independente

(modelo *end-to-end*). Nesse estudo, o percentual de identificação de placas por parte desse sistema construído foi de 90%. Em menor escala, sistemas de reconhecimento em tempo real de placas a partir de vídeos dinâmicos também apontaram para cenários de apoio remoto, telemedicina e triagem automatizada.³⁰

Ao observar o conjunto dessas aplicações, emerge um padrão claro. As áreas mais avançadas hoje são detecção, segmentação e classificação de placas em imagens modo B, já acompanhadas por incursões relevantes em CEUS, ultrassonografia 3D, radiômica e estratificação de risco. O campo, contudo, ainda se caracteriza mais por prova de capacidade do que por incorporação plena à prática assistencial. Em muitos casos, a IA já demonstra que pode se igualar ou superar a análise visual em tarefas específicas; o passo seguinte é mostrar que essa superioridade é estável, generalizável e clinicamente útil.^{16,23,26}

Modalidades avançadas de imagem e sua integração com a IA

A evolução recente da ultrassonografia de carótidas tem ampliado de forma importante o espectro de informações extraídas do exame. Se o ultrassom bidimensional convencional continua sendo a base da avaliação, as modalidades avançadas como CEUS, elastografia, ultrassonografia 3D, técnicas de microfluxo e métodos de super-resolução passaram a oferecer acesso mais refinado à composição, à biomecânica e à microcirculação da placa.^{1,20,21,38}

Entre essas modalidades, o CEUS se destaca. Ele permite caracterizar, com maior precisão, a superfície da placa carotídea e detectar biomarcadores de vulnerabilidade, particularmente a neovascularização intraplaca relacionada a um aumento do risco de eventos cerebrovasculares. O CEUS acrescenta uma dimensão funcional à ultrassonografia convencional, e seus achados se associam à presença de placa vulnerável, inclusive com correlação histológica.³⁹⁻⁴⁴ A integração de IA com CEUS parece promissora porquanto o contraste gera grande volume de informação dinâmica. Modelos de aprendizado profundo podem realizar segmentação multitarefa e avaliação automatizada de vulnerabilidade em imagens e vídeos de CEUS.¹⁷ A combinação entre características derivadas do modo B e do CEUS, analisadas por IA, melhora a predição de placas vulneráveis associadas a AVC isquêmico agudo.^{17,32}

As técnicas de imagem de fluxo microvascular representam uma evolução dos métodos convencionais de Doppler e foram desenvolvidas para detectar fluxos sanguíneos de baixa velocidade em vasos de pequeno calibre, sem a necessidade de CEUS endovenoso. A imagem de fluxo microvascular utiliza algoritmos adaptativos que conseguem separar os verdadeiros sinais de fluxo dos artefatos causados pelo movimento dos tecidos, preservando sinais de baixa velocidade. Nessa conjuntura, o software analisa as características espaciais e temporais dos ecos ultrassonográficos para distinguir o movimento de tecido (artefato) do fluxo sanguíneo verdadeiro. Na avaliação ultrassonográfica das carótidas, essa tecnologia, além de permitir a visualização da microvascularização intraplaca,

pode melhorar a delimitação do lúmen e da parede, refinar a avaliação da estenose e auxiliar na identificação de ulcerações.^{20,44} Estudos demonstram excelente concordância entre a imagem de fluxo microvascular e o CEUS na detecção da neovascularização intraplaca, além da correlação com achados histopatológicos, reforçando seu potencial como ferramenta não invasiva para avaliar a vulnerabilidade das placas carotídeas.⁴⁵

O exemplo mais sofisticado dessa tendência é a microscopia por localização ultrassônica (ULM), capaz de avaliar o fluxo microvascular em placas carotídeas humanas com resolução muito superior à do ultrassom convencional e com correlação histológica.²¹

A elastografia, por sua vez, introduz a dimensão biomecânica à análise da placa. Tanto a elastografia por deformação quanto a por ondas de cisalhamento buscam inferir propriedades mecânicas da parede do vaso e da placa, partindo do princípio de que lesões com composições diferentes apresentam rigidez e padrões de deformações distintas.^{19,46,47} Estudos recentes sugerem que a elastografia pode diferenciar placas vulneráveis e se associar a desfechos clínicos.^{35,47,48} A aplicação de IA nesse campo pode ser especialmente útil ao integrar mapas de elasticidade com informações morfológicas, texturais e clínicas.⁴⁶

A ultrassonografia 3D acrescenta outra camada importante ao exame. Sua principal contribuição é permitir uma avaliação mais fiel da carga aterosclerótica, especialmente por meio de medidas volumétricas. Ao contrário da imagem bidimensional, que captura apenas recortes da lesão, o modo 3D permite reconstrução do volume da placa, melhor análise da superfície e monitorização longitudinal mais robusta.^{18,49,50} A integração entre o recurso 3D e IA é particularmente natural, visto que a análise volumétrica manual é mais trabalhosa e dependente do examinador.⁴⁹⁻⁵¹

Observado em conjunto, esse arsenal deixa claro que o futuro da ultrassonografia carotídea é multiparamétrico. A imagem bidimensional fornece morfologia básica; o CEUS revela neovascularização; a elastografia informa biomecânica; o microfluxo explora fluxos em vasos com velocidades muito baixas; a ultrassonografia 3D quantifica carga e volume; e técnicas de super-resolução aproximam a imagem da histologia.^{1,20,21}

Limitações metodológicas e desafios para implementação clínica

A literatura sobre IA aplicada ao ultrassom carotídeo vem crescendo rapidamente, mas sua interpretação exige cautela metodológica. Em termos gerais, os estudos diferem não apenas em arquitetura algorítmica, tamanho amostral ou modalidade de imagem, mas principalmente no tipo de padrão de referência adotado para treinar e validar os modelos. Na prática, esse desfecho costuma se apoiar em três eixos principais: avaliação por especialista, histologia e desfecho clínico.^{23,26}

O padrão de referência baseado em especialista é, hoje, o mais frequente. Essa estratégia tem a vantagem de ser factível, escalável e próxima da prática clínica real.

O problema é que ela carrega a própria variabilidade humana que a IA se propõe a reduzir. Em outras palavras, o algoritmo pode se tornar excelente em reproduzir o padrão interpretativo de um especialista ou centro específico, sem necessariamente capturar a biologia real da lesão. Isso ajuda a explicar por que tantos estudos apresentam ótimo desempenho interno, mas ainda deixam dúvida sobre generalização e validade externa.^{23,25,26} As revisões metodológicas disponíveis reforçam esse alerta. Embora muitos modelos, especialmente os radiômicos, apresentem AUCs elevadas, a qualidade metodológica média ainda é baixa, com elevado risco global de vieses e fragilidades em seleções de variáveis, validação e reprodutibilidade.^{23,26}

O padrão de referência histológico ocupa uma posição metodologicamente mais consistente, pois ancora a imagem em desfechos biológicos concretos. Em estudos de placa carotídea, a histologia permite validar características como neovascularização, núcleo lipídico-necrótico, hemorragia intraplaca, inflamação e composição tecidual. Trabalhos com CEUS, elastografia, imagem 3D e ULM ganham enorme força quando correlacionados à peça de endarterectomia.^{21,43,50} Ainda assim, a histologia também tem limitações: deriva de populações precisamente selecionadas, geralmente com doença mais avançada e indicação cirúrgica, o que reduz sua representatividade para o espectro mais amplo da prática ambulatorial.

O terceiro eixo, e talvez o mais importante para a implementação real, é o uso de desfechos clínicos. Aqui, o valor da IA deixa de ser medido apenas pela concordância com a imagem ou com a histologia e passa a ser julgado por sua capacidade de prever eventos cardiovasculares, progressão da doença ou necessidade de intervenção. Essa abordagem é clinicamente a mais relevante, mas também a mais difícil, pois exige coortes maiores, seguimentos mais longos, controle de vieses e modelos mais estáveis.

Esses diferentes níveis de padrões de referência mostram que a implementação clínica da IA depende tanto de acurácia algorítmica como de qual pergunta o modelo realmente responde. Um algoritmo treinado para reproduzir contornos manuais de um especialista resolve um problema diferente de outro que foi validado contra histologia e ambos resolvem um problema distinto de um sistema capaz de prever evento clínico futuro. Para que a IA avance de forma consistente no ultrassom carotídeo, é necessário articular esses níveis em uma hierarquia translacional: primeiro, boa segmentação e robustez técnica; depois, validação biológica e, finalmente, demonstração de valor prognóstico e impacto em conduta clínica diária.^{2,5,23,26}

Em síntese, o grande desafio atual não é apenas criar modelos mais complexos, mas construir estudos em que o desfecho de referência seja claro, relevante e clinicamente defensável. Sem isso, há o risco de se obter algoritmos tecnicamente impressionantes, porém treinados para reproduzir representações frágeis da doença. A implementação real da IA em carótidas dependerá menos de desempenho em bancos de dados fechados e mais da capacidade de conectar imagem, biologia e evento clínico em modelos validados, reprodutíveis e úteis à prática.^{21,23,26}

Novas Perspectivas

As perspectivas futuras da IA na ultrassonografia de carótidas apontam menos para a substituição do especialista e mais para a construção de um ecossistema de imagem progressivamente quantitativo, multiparamétrico e orientado por risco. O campo parece caminhar para uma convergência entre automação da aquisição, segmentação robusta, fenotipagem avançada da placa e integração com desfechos clínicos.^{1,20,21}

Um dos eixos mais promissores é a evolução da IA de sistemas de classificação retrospectiva para modelos multimodais. A tendência não é que o algoritmo analise apenas a imagem modo B, mas que combine informações de textura, volume de placa, neovascularização por CEUS, microfluxo, biomecânica por elastografia, hemodinâmica local e variáveis clínicas/laboratoriais. Estudos recentes já sugerem que o desempenho melhora quando mais de uma fonte de informação é integrada, o que reforça a ideia de que a vulnerabilidade da placa dificilmente será capturada por um único marcador.^{21,32,33,48}

Outro eixo de transformação é a automação do próprio exame. O desenvolvimento de sistemas robóticos e de aquisição assistida sugere que parte da variabilidade atualmente atribuída ao operador poderá ser reduzida já na etapa de obtenção da imagem.³⁷ A médio prazo, a IA pode atuar tanto na leitura quanto na orientação em tempo real do examinador, na padronização automática de planos e na seleção dos melhores quadros para análise.^{1,3}

Destaca-se ainda o avanço em direção à super-resolução e à quantificação direta da microcirculação da placa. A ULM talvez seja hoje o exemplo mais claro dessa fronteira, ao permitir visualização e quantificação de neovasos com resolução muito superior à do ultrassom convencional.²¹ De maneira semelhante, as técnicas de microfluxo sem contraste podem evoluir de ferramentas promissoras, porém heterogêneas, para biomarcadores mais padronizados, especialmente se acopladas a algoritmos de quantificação e classificação.^{20,21}

Conclusão

A IA está redefinindo a ultrassonografia de carótidas, convertendo-a de um exame predominantemente anatômico e operador-dependente em uma ferramenta progressivamente mais quantitativa, integrada e orientada à estratificação do risco.

É nesse contexto — e não na competição com o olhar clínico — que reside a verdadeira contribuição da tecnologia.

Referências

1. Varennes O, Goudot G, Soudet S, Sevestre MA. Noninvasive Ultrasound Assessment of Atherosclerotic Plaques: From Anatomical Insights to Recent Technical Advances. *J Am Soc Echocardiogr.* 2026;39(7):673-682. doi: 10.1016/j.echo.2026.04.008.
2. Nicolaides AN, Panayiotou AG, Griffin MB, Tyllis T, Kyriacou E, Avraamides C, et al. Atherosclerotic Cardiovascular Disease Risk Based on SCORE Algorithms and Reclassification Based on Preclinical Atherosclerotic Plaques. *Int Angiol.* 2024;43(5):519-32. doi: 10.23736/S0392-9590.24.05248-9.
3. Johri AM, Nambi V, Naqvi TZ, Feinstein SB, Kim ESH, Park MM, et al. Recommendations for the Assessment of Carotid Arterial Plaque by Ultrasound for the Characterization of Atherosclerosis and Evaluation of Cardiovascular Risk: From the American Society of Echocardiography. *J Am Soc Echocardiogr.* 2020;33(8):917-33. doi: 10.1016/j.echo.2020.04.021.
4. Naylor R, Rantner B, Ancetti S, Borst GJ, De Carlo M, Halliday A, et al. Editor's Choice - European Society for Vascular Surgery (ESVS) 2023 Clinical Practice Guidelines on the Management of Atherosclerotic Carotid and Vertebral Artery Disease. *Eur J Vasc Endovasc Surg.* 2023;65(1):7-111. doi: 10.1016/j.ejvs.2022.04.011.
5. Naqvi TZ, Chao CJ, Butterfield RJ, Wen S, Zhang N. Effect of Detection of Subclinical Atherosclerosis on Carotid Ultrasound on Cardiovascular

O especialista, longe de perder espaço, torna-se ainda mais essencial, agora apoiado por um recurso que aumenta a precisão, a agilidade e a eficiência da análise e que atribui à ultrassonografia carotídea um papel cada vez mais relevante na identificação do risco individual, promovendo uma abordagem mais personalizada da doença vascular.

Contribuição dos Autores

Concepção e desenho da pesquisa, obtenção de dados, análise e interpretação dos dados, análise estatística, redação do manuscrito e revisão crítica do manuscrito quanto ao conteúdo intelectual importante: Dannenhauer G, Santos SN, Petisco ACGP, Freire CMV, Albricker ACL, Barros FS.

Potencial Conflito de Interesse

Não há conflitos de interesses pertinentes.

Fontes de Financiamento

O presente estudo não contou com fontes de financiamento externas.

Vinculação Acadêmica

Não há vinculação deste estudo a programas de pós-graduação.

Aprovação Ética e Consentimento Informado

Este artigo não contém estudos com humanos ou animais realizados por nenhum dos autores.

Uso de Inteligência Artificial

Durante a preparação deste trabalho, o(s) autor(es) usaram ChatGPT para pesquisa de referências bibliográficas e montagem da figura central do estudo. Após o uso desta ferramenta/serviço, o(s) autor(es) revisaram e editaram o conteúdo conforme necessário e assumem total responsabilidade pelo conteúdo do artigo publicado.

Disponibilidade de Dados

Os conteúdos subjacentes ao texto da pesquisa estão contidos no manuscrito.

- Events in a Primary Prevention Clinical Setting. *J Am Soc Echocardiogr*. 2025;38(10):902-15. doi: 10.1016/j.echo.2025.06.009.
6. Matangi MF, Héту MF, Armstrong DWJ, Shellenberger J, Brouillard D, Baker J, et al. Carotid Plaque Score is Associated with 10-Year Major Adverse Cardiovascular Events in Low-Intermediate Risk Patients Referred to a General Cardiology Community Clinic. *Eur Heart J Cardiovasc Imaging*. 2025;26(4):714-24. doi: 10.1093/ehjci/jeae153.
7. Mach F, Koskinas KC, van Lennep JER, Tokgözoğlu L, Badimon L, Baigent C, et al. 2025 Focused Update of the 2019 ESC/EAS Guidelines for the Management of Dyslipidaemias. *Eur Heart J*. 2025;46(42):4359-78. doi: 10.1093/eurheartj/ehaf190.
8. Albricker ACL, Freire CMV, Santos SND, Alcantara ML, Cantisano AL, Porto CLL, et al. Recommendation Update for Vascular Ultrasound Evaluation of Carotid and Vertebral Artery Disease: DIC, CBR and SABCV - 2023. *Arq Bras Cardiol*. 2023;120(10):e20230695. doi: 10.36660/abc.20230695.
9. Santos SND, Alcantara ML, Freire CMV, Cantisano AL, Teodoro JAR, Porto CLL, et al. Vascular Ultrasound Statement from the Department of Cardiovascular Imaging of the Brazilian Society of Cardiology - 2019. *Arq Bras Cardiol*. 2019;112(6):809-49. doi: 10.5935/abc.20190106.
10. Saba L, Cau R, Murgia A, Nicolaides AN, Wintermark M, Castillo M, et al. Carotid Plaque-RADS: A Novel Stroke Risk Classification System. *JACC Cardiovasc Imaging*. 2024;17(1):62-75. doi: 10.1016/j.jcmg.2023.09.005.
11. Huang Z, Cheng XQ, Lu RR, Bi XJ, Liu YN, Deng YB. Incremental Prognostic Value of Carotid Plaque-RADS Over Stenosis Degree in Relation to Stroke Risk. *JACC Cardiovasc Imaging*. 2025;18(1):77-89. doi: 10.1016/j.jcmg.2024.07.004.
12. Pakizer D, Kozel J, Taffé P, Elmers J, Feber J, Michel P, et al. Diagnostic Accuracy of Carotid Plaque Instability by Noninvasive Imaging: A Systematic Review and Meta-Analysis. *Eur Heart J Cardiovasc Imaging*. 2024;25(10):1325-35. doi: 10.1093/ehjci/jeae144.
13. He L, Yang Z, Wang Y, Chen W, Diao L, Wang Y, et al. A Deep Learning Algorithm to Identify Carotid Plaques and Assess their Stability. *Front Artif Intell*. 2024;7:1321884. doi: 10.3389/frai.2024.1321884.
14. Singh S, Jain PK, Sharma N, Pohit M, Roy S. Atherosclerotic Plaque Classification in Carotid Ultrasound Images Using Machine Learning and Explainable Deep Learning. *Intell Med*. 2024;4(2):83-95. doi: 10.1016/j.imed.2023.05.003.
15. Zhang H, Zhao F. Deep Learning-Based Carotid Plaque Ultrasound Image Detection and Classification Study. *Rev Cardiovasc Med*. 2024;25(12):454. doi: 10.31083/j.rcm.2512454.
16. Eini P, Eini P, Serpoush H, Rezayee M, Tremblay J. Machine Learning Models for Carotid Artery Plaque Detection: A Systematic Review of Ultrasound-Based Diagnostic Performance. *J Stroke Cerebrovasc Dis*. 2025;34(11):108446. doi: 10.1016/j.jstrokecerebrovasdis.2025.108446.
17. Hu B, Zhang H, Jia C, Chen K, Tang X, He D, et al. Automatic Multi-Task Segmentation and Vulnerability Assessment of Carotid Plaque on Contrast-Enhanced Ultrasound Images and Videos via Deep Learning. *IEEE J Biomed Health Inform*. 2026;30(6):4634-45. doi: 10.1109/JBHI.2025.3581686.
18. Yeung K, Eiberg JP, Collet-Billon A, Sandholt BV, Jessen ML, Sillesen HH, et al. 3-D Contrast-Enhanced Fusion Ultrasound for Accurate Volume Assessment of Vessel Lumen and Plaque in Carotid Artery Disease as Compared with Computed Tomography Angiography. *Ultrasound Med Biol*. 2024;50(3):399-406. doi: 10.1016/j.ultrasmedbio.2023.11.013.
19. Kavvadas D, Rafailidis V, Partovi S, Tegos T, Kallia Z, Savvoulidis P, et al. Shear Wave Elastography for Carotid Artery Stiffness: Ready for Prime Time? *Diagnostics*. 2025;15(3):303. doi: 10.3390/diagnostics15030303.
20. Seddiki R, Mirault T, Sitruk J, Mohamedi N, Messas E, Pernot M, et al. Advancements in Noncontrast Ultrasound Imaging for Low-Velocity Flow: A Technical Review and Clinical Applications in Vascular Medicine. *Ultrasound Med Biol*. 2025;51(7):1035-42. doi: 10.1016/j.ultrasmedbio.2025.03.001.
21. Leroy H, Wang LZ, Jimenez A, Mohamedi N, Papadacci C, Julia P, et al. Assessment of Microvascular Flow in Human Atherosclerotic Carotid Plaques Using Ultrasound Localization Microscopy. *EBioMedicine*. 2025;111:105528. doi: 10.1016/j.ebiom.2024.105528.
22. Song J, Zou L, Li Y, Wang X, Qiu J, Gong K. Combining Artificial Intelligence Assisted Image Segmentation and Ultrasound Based Radiomics for the Prediction of Carotid Plaque Stability. *BMC Med Imaging*. 2025;25(1):89. doi: 10.1186/s12880-025-01621-4.
23. Hou C, Liu XY, Du Y, Cheng LG, Liu LP, Nie F, et al. Radiomics in Carotid Plaque: A Systematic Review and Radiomics Quality Score Assessment. *Ultrasound Med Biol*. 2023;49(12):2437-45. doi: 10.1016/j.ultrasmedbio.2023.06.008.
24. Wang DD, Lin S, Lyu GR. Advances in the Application of Artificial Intelligence in the Ultrasound Diagnosis of Vulnerable Carotid Atherosclerotic Plaque. *Ultrasound Med Biol*. 2025;51(4):607-14. doi: 10.1016/j.ultrasmedbio.2024.12.010.
25. Liapi GD, Loizou CP, Pattichis CS, Pattichis MS, Nicolaides AN, Griffin M, et al. Assessing the Impact of Ultrasound Image Standardization in Deep Learning-Based Segmentation of Carotid Plaque Types. *Comput Methods Programs Biomed*. 2024;257:108460. doi: 10.1016/j.cmpb.2024.108460.
26. Hou C, Li S, Zheng S, Liu LP, Nie F, Zhang W, et al. Quality Assessment of Radiomics Models in Carotid Plaque: A Systematic Review. *Quant Imaging Med Surg*. 2024;14(1):1141-54. doi: 10.21037/qims-23-712.
27. Zhou R, Ou Y, Fang X, Azarpazhooh MR, Gan H, Ye Z, et al. Ultrasound Carotid Plaque Segmentation Via Image Reconstruction-Based Self-Supervised Learning with Limited Training Labels. *Math Biosci Eng*. 2023;20(2):1617-36. doi: 10.3934/mbe.2023074.
28. Jadoon M, Poli F, Boutouryie P, Khettab H, Joywin-Melitus G, Sam DO, et al. Radiomics-Based Classification of Pathological Patterns in Common Carotid Artery Wall. *Ultrasound Med Biol*. 2026;52(7):1287-93. doi: 10.1016/j.ultrasmedbio.2026.02.017.
29. Liu Y, Kong Y, Yan Y, Hui P. Explore the Value of Carotid Ultrasound Radiomics Nomogram in Predicting Ischemic Stroke Risk in Patients with Type 2 Diabetes Mellitus. *Front Endocrinol*. 2024;15:1357580. doi: 10.3389/fendo.2024.1357580.
30. Wei Y, Yang B, Wei L, Xue J, Zhu Y, Li J, et al. Real-Time Carotid Plaque Recognition from Dynamic Ultrasound Videos Based on Artificial Neural Network. *Ultraschall Med*. 2024;45(5):493-500. doi: 10.1055/a-2180-8405.
31. Omarov M, Zhang L, Jorshery SD, Malik R, Das B, Bellomo TR, et al. Automated Deep Learning-Based Detection of Early Atherosclerotic Plaques in Carotid Ultrasound Imaging. *medRxiv*. 2025:2024.10.17.24315675. doi: 10.1101/2024.10.17.24315675.
32. Jin ZY, Zhou CY, Tan S, Fan XZ, Li JK, Li SY, et al. Features of B-Mode Ultrasound and Contrast-Enhanced Ultrasound of Carotid Plaque Based on Deep Learning Enhance the Prediction of Vulnerable Plaques Associated with Acute Ischemic Stroke. *Eur Radiol*. 2026;36(7):5257-68. doi: 10.1007/s00330-026-12376-z.
33. Zhang W, Hou C, Wang X, Kang H, Li S, Sun Y, et al. A Novel Dual-Modality Dual-View Hybrid Deep Learning-Machine Learning Framework for the Prediction of Carotid Plaque Vulnerability via Late Fusion. *Diagnostics*. 2026;16(5):807. doi: 10.3390/diagnostics16050807.
34. Zhao T, Lin G, Chen W, Wu J, Hu W, Xu L, et al. Predicting Symptomatic Carotid Artery Plaques with Radiomics-Based Carotid Perivascular Adipose Tissue Characteristics: A Multicenter, Multiclassifier Study. *BMC Med Imaging*. 2025;25(1):337. doi: 10.1186/s12880-025-01876-x.
35. Chen J, Wang J, Wang Q, Sun W, Huo X, Li X. Risk Prediction for Symptomatic Ischemic Cerebrovascular Disease Based on Ultrasound Indicators of Carotid Plaque Neovascularization. *Front Cardiovasc Med*. 2025;12:1648352. doi: 10.3389/fcvm.2025.1648352.
36. Gao Y, Wang H, Zhou D, Mai P, Li X, Li P, et al. A Clinically Deployable Deep Learning Model for Automated Stroke Risk Stratification in Carotid Atherosclerotic Plaque. *Front Med*. 2026;13:1764968. doi: 10.3389/fmed.2026.1764968.

37. Jiang H, Zhao A, Yang Q, Yan X, Wang T, Wang Y, et al. Towards Expert-Level Autonomous Carotid Ultrasonography with Large-Scale Learning-Based Robotic System. *Nat Commun.* 2025;16(1):7893. doi: 10.1038/s41467-025-62865-w.
38. Zhang J, Wu X, Gao Y, Wang L. Morphological and Biomechanical Characteristics of Carotid Plaques with Mild Stenosis Using Ultrafast and High-Definition Ultrasonography. *Eur Radiol.* 2026;36(1):437-49. doi: 10.1007/s00330-025-11816-6.
39. Kopyto E, Czezelewski M, Mikos E, Stępnia K, Kopyto M, Matuszek M, et al. Contrast-Enhanced Ultrasound Feasibility in Assessing Carotid Plaque Vulnerability-Narrative Review. *J Clin Med.* 2023;12(19):6416. doi: 10.3390/jcm12196416.
40. Abou Ali AN, Fittipaldi A, Rocha-Neves J, Ruaro B, Benedetto F, Al Ghadban Z, et al. Clinical Applications of Contrast-Enhanced Ultrasonography in Vascular Surgery: State-of-the-Art Narrative and Pictorial Review. *JVS Vasc Insights.* 2025;3:100254. doi: 10.1016/j.jvsvi.2025.100254.
41. Cao J, Zeng Y, Zhou Y, Yao Z, Tan Z, Huo G, et al. The Value of Contrast-Enhanced Ultrasound in Assessing Carotid Plaque Vulnerability and Predicting Stroke Risk. *Sci Rep.* 2025;15(1):5850. doi: 10.1038/s41598-025-90319-2.
42. Zhou S, Hui P. Predictive Value of Contrast-Enhanced Carotid Ultrasound Features for Stroke Risk: A Systematic Review and Meta-Analysis. *Front Neurol.* 2025;16:1487850. doi: 10.3389/fneur.2025.1487850.
43. Hou C, Xuan JQ, Zhao L, Li MX, He W, Liu H. Comparison of the Diagnostic Performance of Contrast-Enhanced Ultrasound and High-Resolution Magnetic Resonance Imaging in the Evaluation of Histologically Defined Vulnerable Carotid Plaque: A Systematic Review and Meta-Analysis. *Quant Imaging Med Surg.* 2024;14(8):5814-30. doi: 10.21037/qims-24-540.
44. Yang Y, Liu F, Yan J, Luo Y, Huang Q, Qiao L. Current Status and Advances in Ultrasound Evaluation of Neovascularization within Carotid Artery Plaques: A Systematic Review. *Cardiovasc Ultrasound.* 2025;23(1):19. doi: 10.1186/s12947-025-00356-0.
45. Song Y, Xing H, Zhang Z, Felix LO. Detection of Carotid Atherosclerotic Intraplaque Neovascularization Using Superb Microvascular Imaging: A Meta-Analysis. *J Ultrasound Med.* 2021;40(12):2629-38. doi: 10.1002/jum.15652.
46. Tang X, Zhang L, He D, Hu B, Jia C, Gu S, et al. Automatic Generation and Risk Stratification of Carotid Plaque in Virtual Shear Wave Elastography Using a Generative Adversarial Network. *Comput Med Imaging Graph.* 2025;124:102600. doi: 10.1016/j.compmedimag.2025.102600.
47. Li M, Weng S, Song Q, Ge H. Study on the Prediction of Short-Term Clinical Changes after Cerebral Infarction Using Carotid Plaque Ultrasound Strain Elastography. *Front Neurol.* 2025;16:1652157. doi: 10.3389/fneur.2025.1652157.
48. Sultan SR, Hajji FA, Fatani M, Albngali A, Alfatni A, Alsalamah A, et al. Quantitative Ultrasound SWE of Carotid Plaque in Symptomatic and Asymptomatic Patients: A Systematic Review and Meta-Analysis. *Diagnostics.* 2026;16(7):1085. doi: 10.3390/diagnostics16071085.
49. Phair AS, Carreira J, Bowling FL, Ghosh J, Smith C, Rogers SK. Accelerated Measurement of Carotid Plaque Volume Using Artificial Intelligence Enhanced 3D Ultrasound. *Ann Vasc Surg.* 2024;98:317-24. doi: 10.1016/j.avsg.2023.06.018.
50. López-Melgar B, Mass V, Nogales P, Sánchez-González J, Entrekin R, Collet-Billon A, et al. New 3-Dimensional Volumetric Ultrasound Method for Accurate Quantification of Atherosclerotic Plaque Volume. *JACC Cardiovasc Imaging.* 2022;15(6):1124-35. doi: 10.1016/j.jcmg.2022.01.005.
51. Li J, Huang Y, Song S, Chen H, Shi J, Xu D, et al. Automatic Diagnosis of Carotid Atherosclerosis Using a Portable Freehand 3-D Ultrasound Imaging System. *IEEE Trans Ultrason Ferroelectr Freq Control.* 2024;71(2):266-79. doi: 10.1109/TUFFC.2023.3345740.



Este é um artigo de acesso aberto distribuído sob os termos da licença de atribuição pelo Creative Commons