

Inteligencia artificial en trauma vascular periférico: una revisión y perspectivas

Artificial intelligence in peripheral vascular trauma: a review and future directions

10.20960/angiologia.00813

02/19/2026

Inteligencia artificial en trauma vascular periférico: una revisión y perspectivas

Artificial intelligence in peripheral vascular trauma: a review and future directions

Daniela Arbeláez Lelión¹, Mateo José Murcia Ramos¹, Samuel Salgado Uribe¹, Laura Uribe González¹, María Adriana Serrano Gamboa²

¹Universidad Pontificia Bolivariana. Medellín, Colombia. ²Servicio de Cirugía General. Universidad Industrial de Santander. Bucaramanga, Colombia

Correspondencia: Daniela Arbeláez Lelión. Universidad Pontificia Bolivariana. C/ 78B #72a-159. Medellín, Colombia
e-mail: daniela.arbelaezl@upb.edu.co

Recibido: 04/08/2025

Aceptado: 19/08/2025

Conflictos de interés: los autores declaran no tener conflictos de interés. Inteligencia artificial: los autores declaran no haber usado inteligencia artificial (IA) ni ninguna herramienta que use IA para la redacción del artículo.

RESUMEN

El trauma vascular periférico representa una causa importante de morbilidad, de amputación y de mortalidad en contextos de trauma mayor. Las herramientas tradicionales, como la angiografía y las escalas clínicas, presentan limitaciones para identificar lesiones viables o tomar decisiones quirúrgicas oportunas. Esta revisión describe críticamente las aplicaciones actuales de la inteligencia artificial en el diagnóstico por imagen, la predicción de complicaciones y el apoyo en la toma de

decisiones en trauma vascular periférico. Se identificaron modelos basados en redes neuronales, árboles de decisión y algoritmos de aprendizaje profundo que han demostrado desempeños superiores a los métodos convencionales en sensibilidad, especificidad y valor predictivo. Además, se exploró su uso potencial en segmentación automática, estratificación de riesgo y alertas clínicas. A pesar de estos avances, persisten barreras en cuanto a su validación externa, su explicación y su aplicabilidad en sistemas de salud de países en desarrollo. Se concluye que la inteligencia artificial constituye una herramienta prometedora en cirugía vascular traumática, cuyo impacto dependerá de su integración clínica, validación ética y entrenamiento con datos regionales.

Palabras clave: Inteligencia artificial. Aprendizaje automático. Traumatismos del sistema vascular. Amputación. Valor predictivo de las pruebas.

ABSTRACT

Peripheral vascular trauma is a major cause of morbidity, amputation, and mortality in severe trauma settings. Traditional tools such as angiography and clinical scoring systems have limitations in accurately identifying viable tissue and guiding timely surgical decisions. This review critically analyzes current applications of artificial intelligence in imaging diagnosis, complication prediction, and surgical decision support in peripheral vascular trauma. We identified models based on neural networks, decision trees, and deep learning algorithms with superior performance compared to conventional methods in sensitivity, specificity, and predictive value. Their potential use in automatic segmentation, risk stratification, and clinical alerts was also explored. Despite these advances, key barriers remain in external validation, algorithm explain ability, and integration into low-resource healthcare systems. In conclusion, artificial intelligence offers a promising tool in

traumatic vascular surgery, whose clinical impact will depend on effective integration, ethical validation, and training with local data.

Keywords: Artificial intelligence. Machine learning. Vascular trauma. Amputation. Predictive value of tests.

INTRODUCCIÓN

El trauma vascular periférico representa una causa significativa de morbilidad y discapacidad, particularmente en contextos de trauma mayor y conflicto armado, como Colombia, donde los datos son variables y la incidencia va del 0,3 al 21,2 %. Las lesiones arteriales en extremidades, tanto por mecanismos cerrados como penetrantes, pueden comprometer gravemente la perfusión tisular y derivar en amputaciones si no se realizan un diagnóstico y una intervención oportunos. En Estados Unidos, por ejemplo, se ha reportado que la tasa de amputaciones traumáticas en lesiones vasculares periféricas supera el 40 % en ciertas cohortes, con implicaciones funcionales y psicológicas devastadoras para los pacientes (1). Pese a los avances en imagenología y técnicas quirúrgicas, el diagnóstico y el pronóstico del trauma vascular aún dependen en gran medida de la angiografía convencional, el juicio clínico y escalas como la del Mangled Extremity Severity Score (MESS). Sin embargo, estos métodos presentan limitaciones importantes. Por ejemplo, el MESS ha mostrado baja sensibilidad para predecir amputación, incluso con puntuaciones elevadas, lo que limita su utilidad en escenarios complejos (2). Asimismo, los estudios han demostrado que la localización anatómica de las lesiones y las variables dinámicas como el uso de transfusiones o la puntuación ISS tienen, en muchos casos, un valor predictivo más robusto que los métodos tradicionales (1,2).

En este contexto, la inteligencia artificial (IA), y específicamente las técnicas de aprendizaje automático (*machine learning*, ML) y de

aprendizaje profundo (*deep learning*, DL), han emergido como herramientas prometedoras para transformar la atención en trauma vascular periférico. Estas tecnologías permiten analizar grandes volúmenes de datos clínicos, hemodinámicos e imagenológicos para detectar patrones complejos no evidentes al ojo humano ni capturables por los modelos estadísticos convencionales (3,4).

Los modelos basados en redes neuronales artificiales, como las redes convolucionales (CNN) o los algoritmos tipo XGBoost, han mostrado una capacidad superior para predecir eventos adversos como amputaciones, necesidad de reintervención o fracaso de revascularización. En trauma vascular, redes neuronales entrenadas con variables como el ISS, la escala de coma de Glasgow (GCS) y los requerimientos transfusionales lograron un área bajo la curva (AUC) de 0,78 en la predicción de amputación, superando ampliamente el desempeño de las herramientas clínicas tradicionales (1). Además, estudios recientes sugieren que los modelos de ML permiten una clasificación más precisa del riesgo, mejorando la toma de decisiones clínicas incluso en escenarios de incertidumbre (1-3).

Frente a este panorama, el objetivo de esta revisión narrativa es describir críticamente las aplicaciones actuales de inteligencia artificial en el diagnóstico, el pronóstico y el apoyo quirúrgico del trauma vascular periférico, con énfasis en su capacidad para superar las limitaciones de los métodos convencionales y mejorar los desenlaces clínicos.

BASES DE LA INTELIGENCIA ARTIFICIAL EN CIRUGÍA VASCULAR Y TRAUMA

La inteligencia artificial (IA) ha emergido como una herramienta transformadora en la medicina vascular y el trauma, facilitando el análisis de datos complejos, la predicción de resultados clínicos y el apoyo en la toma de decisiones quirúrgicas. En este contexto, es

esencial comprender las bases conceptuales que sustentan su aplicación clínica. La IA engloba diversas técnicas computacionales que buscan emular procesos cognitivos humanos. Dentro de sus ramas más relevantes en salud se encuentran el *machine learning* (ML), el *deep learning* (DL) y las redes neuronales artificiales (ANN) (5). El ML es una subdisciplina de la IA que permite a los sistemas aprender de datos estructurados y mejorar su rendimiento sin ser explícitamente programados para cada tarea. A su vez, el DL es una forma avanzada de ML que utiliza múltiples capas de procesamiento (redes neuronales profundas) para identificar patrones complejos, particularmente útil en el análisis de imágenes médicas y procesamiento de lenguaje natural (5).

En cirugía vascular, los algoritmos de ML se han utilizado con éxito para predecir el riesgo de amputación y de complicaciones posoperatorias. Por ejemplo, modelos de aprendizaje profundo (*deep neural networks*) entrenados con variables clínicas y fisiológicas han mostrado capacidades predictivas superiores al juicio clínico aislado en la predicción de cicatrización de heridas y en la necesidad de reintervención en pacientes con isquemia crítica de extremidades (1,2). En trauma vascular, modelos basados en redes neuronales han sido capaces de predecir la probabilidad de amputación tras lesiones vasculares periféricas traumáticas, alcanzando un área bajo la curva (AUC) de hasta 0,78 al integrar variables como el ISS, GCS y transfusiones tempranas (1).

Tradicionalmente, la toma de decisiones clínicas en cirugía vascular y trauma se ha sustentado en modelos estadísticos como la regresión logística, escalas de puntuación clínica (por ejemplo, el MESS para extremidades traumatizadas) y protocolos derivados de consenso de expertos. Si bien estos métodos han sido fundamentales, presentan limitaciones al analizar grandes volúmenes de datos no estructurados, relaciones no lineales o interacciones complejas entre variables clínicas,

imagenológicas y fisiológicas (2). A diferencia de los modelos estadísticos clásicos, como la regresión logística, los algoritmos de ML (p. ej., XGBoost o *random forest*) pueden manejar de forma eficiente grandes volúmenes de variables con relaciones no lineales y multicolineales. En estudios recientes sobre amputaciones mayores, XGBoost ha demostrado un desempeño superior con un AUC de hasta 0,94 en modelos posoperatorios, superando ampliamente a los modelos tradicionales (AUC: 0,70) (6). Asimismo, la red neuronal artificial (ANN) superó al modelo de regresión logística en la predicción del fracaso de revascularización en soldados con fracturas abiertas del calcáneo, ofreciendo mejor discriminación y estratificación de riesgo en múltiples umbrales, lo que potencia su utilidad clínica. En comparación, modelos como el MESS han mostrado baja sensibilidad para predecir amputación incluso en puntuaciones altas, lo que evidencia su escasa utilidad en la práctica moderna (2).

En entornos de imagen médica, especialmente en radiología intervencionista, los modelos tradicionales requieren un alto grado de supervisión y de procesamiento manual, mientras que los sistemas basados en redes neuronales convolucionales (CNN) permiten segmentación, clasificación y predicción automática con alta precisión y velocidad (4). Por ejemplo, se ha reportado que estos modelos pueden reducir significativamente los tiempos de interpretación y mejorar la consistencia diagnóstica, incluso en procedimientos complejos (4).

Por último, la ventaja fundamental de los modelos de IA radica en su capacidad de generalización sobre datos nuevos, su autonomía en la selección de variables relevantes mediante ingeniería de características y su posibilidad de ser adaptados continuamente a medida que se incorporan nuevos datos. Esta versatilidad contrasta con la rigidez de los métodos tradicionales, que suelen requerir rediseño completo ante nuevos escenarios clínicos o poblaciones (3,4).

APLICACIONES EN DIAGNÓSTICO POR IMAGEN

Uno de los campos con mayor impacto de la inteligencia artificial (IA) en el trauma vascular periférico es el diagnóstico por imagen. Las técnicas de segmentación automática mediante algoritmos de aprendizaje profundo (*deep learning*, DL), en especial las redes neuronales convolucionales (CNN), han demostrado una importante capacidad para identificar, clasificar y cuantificar lesiones vasculares en estudios como la angiotomografía (angio TC) y la angiorresonancia magnética (angio RM) (4). A diferencia de la evaluación manual, que puede verse afectada por la experiencia del observador y la variabilidad interindividual, los modelos de segmentación automática permiten procesar grandes volúmenes de imágenes con alta velocidad y reproducibilidad (Tabla I). En radiología intervencionista, por ejemplo, se han entrenado CNN capaces de generar imágenes sustraídas directamente a partir de angio TC sin necesidad de adquisiciones previas sin contraste, lo que mejora la detección de lesiones vasculares complejas y evita errores por movimientos respiratorios (4).

Tabla I. Modelos de inteligencia artificial para segmentación automática en diagnóstico por imagen vascular

Estudio (referencia)	Tipo de Imagen	Arquitectura / Algoritmo	Desempeño (sensibilidad [Sens.], especificidad [Espec.] y AUC)	Aplicación clínica
Den Boer y cols. (2023)	Video quirúrgico / Imagen intraoperator	CNN personalizada	Sens.: ~90 %, Espec.: no	Identificación de aorta y pulmón en

	ía		reportada	cirugía
Maktabi y cols. (2023)	Video intraoperatorio (tiroidectomía)	ML supervisado (clasificador)	Precisión media: 68 %, tiempo: 1,4 s/img	Identificación de nervio laríngeo, tiroides, paratiroides
Gao y cols. (2021)	Angiografía (DSA)	GAN (red generativa adversaria)	No se reporta AUC; calidad visual comparable	Generación de imágenes sustraídas sin imagen base
Hashimoto y cols. (2021)	Laparoscopia	ANN (red neuronal artificial)	Precisión: 95 %	Detección automática de conducto cístico y arteria cística
Studier-Fischer y cols. (2022)	Imágenes hiperespectrales	DNN entrenada con 9059 imágenes	Precisión global: 95 %	Diferenciación de 20 tipos de tejidos intraoperatorios
TransONet (2023)	Angiotomografía (CTA) en vasculatura periférica	CNN 3D + segmentación automática	93,5 % (prox.), 80,6 % (distal)	Segmentación automática del árbol arterial desde aorta torácica hasta piernas
Dr-SAM (2024)	Angiografía de extremidades	SAM (<i>Segment Anything</i>)	Segmentación + detección de anomalías	Estimación de diámetros arteriales y detección de

		<i>Model)</i> + análisis estructural	vasculares periféricas	lesiones sin contraste previo
Reddy y cols. (2022)	MDCT Angiografía (trauma de extremidades)	Sistema de puntuación basado en signos radiológicos	Sens.: 83.1 %, Espec.: 70 %, AUC: 0,843	Detección de transección vascular y trombosis postraumática en extremidades

AUC: áreas bajo la curva; ML: *machine learning*; DSA: angiografía por sustracción digital; CTA: angiotomografía; CNN: redes convolucionales; GAN: redes generativas adversarias; ANN: red neuronal artificial; DNN: redes neuronales profundas

Mediante *deep learning* puede diagnosticarse con tomografía y resonancia, pero también se ha maximizado el ultrasonido. Los modelos basados en DL han logrado que la calidad de la imagen vascular por ecografía mejore de manera significativa, incluso sobresaliendo al ultrasonido convencional, gracias a estas arquitecturas que se especializan en reconstruir estructuras microvasculares partiendo de estímulos ruidosos, lo que es crucial en contextos de trauma en los que la visualización precisa de vasos pequeños puede cambiar el curso del tratamiento (1). También se han desarrollado otros modelos que intentan predecir y anticipar un desarrollo grave del cuadro clínico basado en un aprendizaje extenso, analizando datos clínicos e imágenes. Este programa de IA mejora la toma de decisiones y un

diagnóstico temprano, lo que contribuye a evitar el empeoramiento y las complicaciones que puedan aparecer (1,2).

La evidencia actual sugiere que este tipo de programas de IA predictivos en imagenología en trauma están en camino de convertirse en una parte fundamental de la práctica médica, incluido el trauma vascular periférico, con un impulso favorable hacia su instauración habitual en centros de trauma de alta complejidad, teniendo en cuenta las características dinámicas del paciente crítico y las necesidades de abarcar la fisiopatología y sus cambios fisiológicos continuos (1,3).

PREDICCIÓN DE COMPLICACIONES Y DECISIÓN QUIRÚRGICA

La predicción temprana de complicaciones en el trauma vascular periférico, como la pérdida de viabilidad tisular, necesidad de amputación o fallo en la revascularización, representa uno de los mayores retos clínicos para el equipo quirúrgico (6). En este contexto, los modelos de inteligencia artificial (IA) han surgido como herramientas poderosas para apoyar al médico en la toma de decisiones en escenarios de alta complejidad, superando en varios casos el rendimiento de escalas clínicas tradicionales, como el MESS. Algoritmos como XGBoost, Random Forest y redes neuronales profundas se han entrenado con variables clínicas, hemodinámicas e imagenológicas, alcanzando áreas bajo la curva (AUC) de hasta 0,94 para predecir amputación o mortalidad en pacientes con lesiones vasculares graves (1,2,6).

Estas herramientas, además de ofrecer mayor precisión pronóstica, también permiten estratificar el riesgo en tiempo real y pueden sugerir intervenciones, como revascularización urgente o amputación primaria, y así poder mejorar los desenlaces funcionales y reducir la morbilidad quirúrgica (4). Los principales modelos predictivos desarrollados recientemente (Tabla II) para anticipar complicaciones clínicas y guiar decisiones quirúrgicas en el contexto del trauma vascular

periférico. Se incluyen estudios entre 2022 y 2025 que emplean técnicas de inteligencia artificial y aprendizaje automático, como XGBoost, redes neuronales profundas, *random forest*, regresión logística y nomogramas personalizados (1-6). Cada modelo cuenta con distintas variables clínicas relevantes, como edad, comorbilidades, signos vitales, tipo e indicación de amputación, localización anatómica del trauma, mecanismos lesionales, escalas de severidad como ISS y GCS, transfusiones, presencia de necrosis muscular, trombosis venosa profunda (TVP) y marcadores de laboratorio, como el fibrinógeno (1,5,6).

Tabla II. Modelos predictivos de complicaciones y decisiones quirúrgicas en trauma vascular periférico

Estudio (referencia)	Algoritmo / Modelo	Variables utilizadas	Desempeño (AUC, sensibilidad [Sens.] y especificidad [Esp.]	Resultado clínico predicho
Li B y cols. (2025)	XGBoost	Edad, comorbilidades, signos vitales, tipo de amputación	AUC: 0,94 (modelo posoperatorio) o) AUC: 0,85 (modelo preoperatorio)	Mortalidad tras amputación mayor
Kania y cols. (2023) (1)	Red neuronal profunda	ISS, GCS, PAS inicial, transfusiones	AUC: 0,78 Sens.: 74 % Espec.: 76 %	Riesgo de amputación tras trauma vascular periférico

Li y cols. (2022)	<i>Random forest</i> y regresión logística comparativa	Localización anatómica, mecanismos lesionales, comorbilidades	Mejor desempeño con RF en predicción de fracaso de revascularización	Fracaso de revascularización en trauma vascular torácico
Wei D y cols. (2023)	Nomograma usando LASSO y regresión logística	Causa de la lesión, del daño vascular, del <i>shock</i> y del fibrinógeno	AUC del nomograma fue de 0,849	El riesgo de amputación en pacientes con SCA
Tao Wang y cols. (2024)	Nomograma usando análisis de regresión logística binaria y el análisis de la curva característica del operador del receptor (ROC)	Lesiones por aplastamiento, las lesiones por objetos pesados, la necrosis muscular y la TVP	Nomograma con un AUC de 0,9066	Predecir la amputación en pacientes con SCA
Ben Li y cols. (2025)	Gradient Boosting (XGBoost)	Nivel y la indicación de amputación, las comorbilidades y el	AUROC de 0,88	Predecir la mortalidad al año tras una amputación mayor de extremidades

		estado funcional		inferiores.
--	--	---------------------	--	-------------

AUC: áreas bajo la curva; XGBoost: modelo de *gradient boosting*; SCA: síndrome coronario agudo; TVP: trombosis venosa profunda; ROC: operador del receptor.

En cuanto al rendimiento, los modelos reportan áreas bajo la curva (AUC) que oscilan entre 0,78 y 0,91, con sensibilidades y especificidades superiores al 70 %, lo que sugiere una capacidad predictiva robusta. Por ejemplo, el modelo de Adebayo y cols. (7) (2023), basado en XGBoost, alcanzó un AUC de 0,94 en el escenario posoperatorio para predecir la mortalidad tras una amputación mayor. Por otro lado, Kenia y cols. (1) (2022) emplearon una red neuronal profunda para predecir el riesgo de amputación con una sensibilidad del 74 % y una especificidad del 76 %. Estos modelos representan avances significativos hacia una medicina personalizada en el manejo del trauma vascular debido a que facilitan una estratificación del riesgo más precisa y decisiones quirúrgicas basadas en evidencia cuantitativa (1,5,7).

Dentro de los modelos de inteligencia artificial actuales (Tabla III) se evidencia que los algoritmos de redes neuronales profundas (DNN), incluyendo las redes convolucionales (CNN), son los más versátiles, utilizados tanto en segmentación automática de imágenes médicas como en la predicción de amputación y pronóstico posoperatorio (1,4). Por su parte, XGBoost y *random forest* se han empleado especialmente en la predicción de complicaciones, como la mortalidad tras amputación mayor o el fracaso de revascularización, mostrando desempeños superiores a los métodos tradicionales en varios estudios (4). No obstante, su uso aún no se ha extendido al campo del diagnóstico

imagenológico, probablemente debido a su naturaleza tabular y no espacial.

Tabla III. Aplicación de modelos de inteligencia artificial según tipo y finalidad clínica

Tipo de Modelo / Algoritmo	Diagnóstico por Imagen	Predicción de amputación	Seguimiento / Pronóstico
CNN (red neuronal convolucional)	✓	✗	✓
Red neuronal profunda (DNN)	✓	✓	✓
XGBoost	✗	✓	✓
<i>Random forest</i>	✗	✓	✗
Regresión logística	✗	✓ (comparador)	✗
GAN (red generativa adversaria)	✓	✗	✗
Radiomics tradicional	✓	✗	✓

En contraste, técnicas como las redes generativas adversarias (GAN) se han utilizado en entornos específicos de imagen, como la angiografía digital, para generar imágenes sustraídas sin necesidad de adquisición basal, y han mostrado su utilidad en escenarios perioperatorios, pero sin aplicación directa en pronóstico ni en predicción de complicaciones (4).

Finalmente, aunque la regresión logística sigue usándose como punto de comparación en muchos estudios, ha demostrado menor precisión que los modelos de ML en la predicción de amputación o de mortalidad (6). Este análisis permite identificar oportunidades para ampliar el uso de ciertos modelos a nuevas fases del manejo clínico del trauma vascular, impulsando futuras investigaciones hacia el diseño de herramientas integradas que combinen predicción y visualización dinámica de lesiones.

INTEGRACIÓN CLÍNICA Y SISTEMAS DE SOPORTE A LA DECISIÓN

En trauma vascular periférico se han desarrollado marcos de modelo de predicción basados en *machine learning* para identificar factores de riesgo y predecir la amputación peritraumática de extremidades inferiores posterior a lesiones arteriales traumáticas, lo que ha demostrado una capacidad predictiva más robusta comparada con el desempeño de ciertas escalas (8). Así, la IA está transformando el campo de la salud por medio de modelos que no solo se utilizan en trauma vascular, sino que incluyen distintos principios, como la optimización de la documentación en los sistemas de historia clínica, diagnóstico de otras patologías, el desarrollo de medicamentos, la robótica quirúrgica, la terapia dirigida y la mejora en el flujo del trabajo médico (9).

Con el fin de mitigar el agotamiento médico, reducir el tiempo que se dedica al trabajo administrativo y mejorar la relación médico-paciente se han propuesto herramientas que incluyen el uso de tecnologías como los asistentes de documentación impulsados por IA. Estos asistentes pueden reducir el tiempo que el personal médico dedica a labores administrativas hasta en un 70 % al transcribir las interacciones con los pacientes, aumentar la eficiencia operativa y la gestión hospitalaria, introducir datos en los registros médicos electrónicos (RME) y procesar información para órdenes y recetas, cuyo objetivo es la automatización

de tareas que consumen mucho tiempo, lo que les permite centrarse en la atención directa al paciente (9,10).

Estas herramientas de IA pueden integrarse en los sistemas de historia clínica y generar cierta ayuda al personal. Por ejemplo, herramientas como 3M y Optum utilizan *machine learning* (ML) para analizar registros médicos en busca de exhaustividad y precisión, sugiriendo diagnósticos potenciales (9,10). Por otro lado, herramientas como Notable y Abridge analizan los encuentros con los pacientes (dictados y notas clínicas) con el fin de generar síntesis de la información de manera estructurada y concisa para así reducir el tiempo dedicado a revisar manualmente las notas, mejorando la eficiencia en la revisión de gráficos y en la identificación de información clave para el médico (9). Sin embargo, existe la necesidad de validar de forma rigurosa estas herramientas de IA con el fin de disminuir al máximo los sesgos y las preocupaciones sobre la privacidad (9).

Con respecto al uso de la IA y de la telemedicina, se han evaluado modelos de inteligencia artificial, incluyendo el *machine learning* (ML), *deep learning* (DL) y el procesamiento del lenguaje natural (NLP), para apoyar la atención de lesiones traumáticas en el entorno prehospitalario. Se realizó una revisión cuyo objetivo principal fue comprender los avances actuales de la IA como apoyo a la toma de decisiones para despachadores, clínicos de los servicios médicos de emergencia (SME) y equipos de trauma, incorporando información clínica, radiómica y genética para mejorar la objetividad y la precisión en la toma de decisiones y así guiar el cuidado temprano de lesiones traumáticas con base en la información prehospitalaria disponible (11).

Los algoritmos de ML y DL pueden identificar y extraer automáticamente características importantes de grandes bases de datos multidimensionales sin programación explícita. Dentro de los hallazgos del estudio se concluyó que aumentar el número de características no mejoró significativamente el rendimiento del modelo, lo que sugiere que

la IA puede ayudar a seleccionar las características más relevantes para predicciones precisas y oportunas, reduciendo la posibilidad de datos faltantes y el sobreajuste. Las características de entrada más comunes fueron: presión arterial sistólica, frecuencia cardíaca, edad, escala de coma de Glasgow y frecuencia respiratoria (11). En este estudio la IA generalmente superó el rendimiento del *Revised Trauma Score* (RTS) y se desempeñó al menos tan bien como TRISS o ISS (puntuaciones que no son factibles de calcular en el entorno prehospitalario) (11). En comparación con la toma humana de decisiones, la IA no siempre superó a los despachadores en casos de rutina, pero mostró mayor precisión cuando la certeza de los despachadores era menor. La IA también superó a los despachadores en la predicción de la prioridad de la llamada y a los clínicos de SME en ambulancia aérea en la estimación del riesgo de coagulopatía inducida por trauma (11).

Adicionalmente se ha descrito sobre las redes convolucionales, en las que las neuronas se organizan espacialmente, toman entradas de píxeles y las procesan en representaciones de orden superior, antes de que esta información pase a capas sucesivas para generar predicciones. De esta forma muestran un fuerte rendimiento diagnóstico para diversas lesiones traumáticas identificables en imágenes médicas; de hecho, se describe que alcanzan más del 90 % de sensibilidad y especificidad para detectar trauma abdominal de órganos sólidos (bazo, hígado y riñón) en tomografías computarizadas (TC), logran hasta un 97 % de precisión en el diagnóstico de fracturas distales del radio en radiografías, un 98 % de sensibilidad para fracturas de cadera en radiografías pélvicas y un AUC (área bajo la curva ROC) superior a 0,80 para la detección de hemorragia intracraneal en TC cerebral, mejorando así las tasas de detección de los radiólogos en un 65,7 % y reduciendo los tiempos de lectura (12). Cuando se combinan las redes convolucionales y el DL, se logra una precisión predictiva aún mayor, con AUC (área bajo la curva ROC) superiores a 0,95 para resultados como hospitalización, mortalidad

y admisión en la UCI (12). A pesar de todos los avances que ha traído consigo la IA, se han propuesto ciertos desafíos éticos significativos que surgen a partir de su incorporación en el campo quirúrgico; incluso se plantea la necesidad de un enfoque multidisciplinario que involucre a distintas partes interesadas con el fin de abordar estos dilemas éticos (13).

Algunas de las preocupaciones éticas que giran en torno a la incorporación de la IA en cirugía son: la privacidad de los datos, ya que para el éxito de la IA se necesita el intercambio de grandes volúmenes de información, lo que plantea incluso desafíos legales y éticos significativos, y adicionalmente el consentimiento informado, ya que se considera esencial que los pacientes estén plenamente informados sobre el uso de sus datos por los sistemas de IA. Puede haber también sesgo algorítmico, ya que los sistemas de IA son demasiado imparciales, al igual que los datos con los que se entrenan, de tal forma que, si esos datos contienen prejuicios históricos, las herramientas de IA pueden replicarlos, llevando a recomendaciones subóptimas o perjudiciales y exacerbando las disparidades en la atención médica (13). Estos y muchos otros desafíos puede representar la IA en su incorporación en la cirugía, como la falta de acceso equitativo en todos los niveles de atención, el impacto en la autonomía humana y la autoridad del cirujano, entre otros (13). Por lo tanto, se necesitan planes equilibrados de estudios que combinen el aprendizaje propuesto y mejorado por la IA con la formación tradicional del personal médico, de tal manera que se eduque sobre cómo utilizar estas tecnologías y cómo integrarlas en la práctica, para así garantizar un equilibrio entre las capacidades avanzadas de la IA y las cualidades humanas que no pueden ser reemplazadas, como la empatía y el juicio ético. Esto hará que se logren estandarizar los sistemas algorítmicos de estas herramientas, que se conviertan en una oportunidad de mejora y que no disminuya la experiencia del paciente (13).

La figura 1 presenta una comparación del desempeño promedio reportado en la literatura reciente para cinco tipos de modelos de inteligencia artificial aplicados al trauma vascular periférico. Se destacan tres métricas claves: el área bajo la curva (AUC), la sensibilidad y la especificidad. Los modelos de tipo XGBoost y CNN muestran el rendimiento más equilibrado y elevado en términos de predicción diagnóstica y pronóstica, superando ampliamente a los métodos tradicionales, como la regresión logística. Esta información apoya el uso de enfoques de aprendizaje automático en contextos críticos de toma de decisiones quirúrgicas y pronóstico clínico. Los valores son aproximados y derivados de múltiples estudios incluidos en esta revisión (1,4,6,14,15).




Figura 1. Desempeño de modelos de inteligencia artificial en trauma vascular periférico. Realizada por los autores.

RETOS Y PERSPECTIVAS

En resumen, podríamos concluir que la inteligencia artificial (IA), particularmente mediante algoritmos de aprendizaje automático (ML) y

aprendizaje profundo (DL), ha avanzado sustancialmente en su aplicación en el trauma vascular periférico (15). Las áreas con mayor desarrollo incluyen la segmentación automática de imágenes en angio TC y angio RM mediante redes neuronales convolucionales (CNN)(15), así como la predicción de complicaciones graves, como amputación, mortalidad o fracaso de revascularización, utilizando modelos como XGBoost y *random forest* (6,16) Se observó, además, el uso creciente de redes profundas entrenadas con datos clínicos complejos que alcanzaron desempeños superiores al de las escalas clínicas tradicionales como el MESS en la predicción de resultados posoperatorios (16).

Desde una perspectiva práctica, estas herramientas podrían transformar la toma de decisiones tanto para el cirujano vascular como para el médico de Urgencias en contextos de alta presión diagnóstica. La capacidad de detectar automáticamente lesiones vasculares críticas en imágenes o de predecir la no viabilidad de un miembro antes de llegar a quirófano permitirían optimizar la asignación de recursos, reducir tiempos operatorios y guiar la indicación de amputación primaria o de revascularización urgente. Sin embargo, aún son escasos los sistemas que logran integrar estos modelos directamente en plataformas clínicas de uso cotidiano, como los HIMS o las estaciones PACS, lo que limita su aplicabilidad inmediata en el entorno hospitalario (16).

En comparación con otras especialidades quirúrgicas, como neurocirugía y trauma general, el desarrollo de IA en cirugía vascular ha sido más lento, pero se encuentra en proceso de aceleración. En neurotrauma, por ejemplo, se han desarrollado modelos que predicen con alta precisión la evolución de lesiones intracraneales en tomografía y riesgo de deterioro neurológico. En trauma general, los algoritmos se utilizan para clasificar automáticamente mecanismos de lesiones, priorizar cirugías y estimar requerimientos de transfusión. En contraste, en trauma vascular periférico los avances son más recientes y se concentran principalmente en la predicción de amputación y en la

segmentación anatómica, como lo muestran los estudios de Li B y cols. (6) y Kania y cols. (1). Como se muestra en la figura 2, las aplicaciones actuales de la inteligencia artificial en el trauma vascular periférico se concentran en regiones anatómicas específicas y fases concretas del proceso clínico. Esta distribución revela tanto los avances ya logrados como las áreas aún no exploradas, lo que abre el camino a futuras investigaciones dirigidas a mejorar la cobertura anatómica, la precisión diagnóstica y la aplicabilidad quirúrgica de estos modelos.


A pesar del prometedor despliegue de herramientas de inteligencia artificial en el trauma vascular periférico, aún persisten limitaciones importantes que restringen su aplicabilidad generalizada. Uno de los principales desafíos es la falta de interoperabilidad entre los modelos de IA y los sistemas clínicos de historia médica electrónica (HCE), lo que dificulta su integración en la toma de decisiones en tiempo real (6). Aunque existen algoritmos con alta precisión en entornos experimentales, su validación en contextos clínicos reales sigue siendo escasa (2).

Asimismo, muchas de las soluciones actuales se han entrenado con bases de datos retrospectivas, en su mayoría provenientes de sistemas de salud norteamericanos o asiáticos, lo que compromete su validez externa en entornos latinoamericanos o en regiones con diferencias anatómicas, epidemiológicas y logísticas (1,6). Esta dependencia de datos homogéneos puede perpetuar sesgos y reducir la aplicabilidad de los modelos en poblaciones diversas, así como la validación de los datos en contextos socioculturales diferentes, con recursos y necesidades específicas particulares de cada población (6).

Otro obstáculo es la limitada aplicabilidad clínica de los modelos, particularmente en redes neuronales profundas. Muchos sistemas funcionan como “cajas negras”, lo que reduce la confianza del personal médico quirúrgico para incorporar sus resultados en decisiones operativas críticas (15). En este contexto, el desarrollo de técnicas de

explainable AI (XAI) representa una prioridad para hacer que los modelos sean auditables, comprensibles y trazables en entornos quirúrgicos.

Finalmente, los modelos actuales suelen centrarse en fases específicas del proceso clínico (diagnóstico por imagen, predicción de complicaciones), pero rara vez abarcan el *continuum* completo del paciente, teniendo en cuenta que el proceso salud-enfermedad es dinámico y abarca desde el ingreso a urgencias hasta el seguimiento posoperatorio. La figura 2 refleja esta fragmentación anatómica y funcional. Superar estas limitaciones requerirá esfuerzos colaborativos que integren ciencia de datos e ingeniería biomédica en un contexto multidisciplinario y con validación clínica multicéntrica. Este artículo presenta las limitaciones propias de una revisión narrativa. Se requieren estudios prospectivos, multicéntricos y clínicamente validados que incluyan poblaciones diversas, en especial de países de ingresos medios y bajos. Es indispensable promover el desarrollo de modelos con aplicabilidad clínica (XAI) capaces de integrarse a protocolos quirúrgicos y de trauma estandarizados. Asimismo, se recomienda el entrenamiento de modelos locales utilizando datos de pacientes latinoamericanos para



mejorar la aplicabilidad regional.



Finalmente, la colaboración entre ingenieros, médicos, instituciones académicas y sistemas hospitalarios



será clave para lograr que la inteligencia artificial se convierta en una herramienta verdaderamente útil, segura y sostenible en el manejo del trauma vascular periférico.



Procesamiento de lenguaje natural (NLP) para análisis clínico e historia médica (seguimiento posoperatorio).

Apoyo a decisiones quirúrgicas en trauma vascular (clasificación riesgo, MESS + ML).

Segmentación automática en angio TC / angio-RM (CNN)

Predicción de amputación, fallo de revascularización (XGBoost, RF, ANN)

Figura 2. Representación anatómica de las aplicaciones actuales de la inteligencia artificial en trauma vascular periférico. En azul, las aplicaciones basadas en procesamiento de lenguaje natural (NLP) para seguimiento posoperatorio. En verde, los modelos de soporte de decisiones quirúrgicas con base en clasificación de riesgo. En naranja, las técnicas de segmentación automática en estudios imagenológicos (angio TC y angio RM), y en rojo, los modelos predictivos de complicaciones, como amputación o falla de revascularización. Adaptado de múltiples estudios incluidos en esta revisión. Figura elaborada por los autores.

CONCLUSIÓN

En conclusión, la inteligencia artificial aplicada al trauma vascular periférico ha demostrado un notable potencial para optimizar el diagnóstico, predecir complicaciones críticas como la amputación y asistir en la toma de decisiones quirúrgicas en escenarios complejos. Modelos como XGBoost, *random forest* y redes neuronales profundas han superado a herramientas convencionales en desempeño pronóstico, especialmente en estudios imagenológicos y predicción de desenlaces.

No obstante, su integración clínica aún se enfrenta a barreras técnicas, éticas y contextuales que deben abordarse mediante validación externa, interoperabilidad con sistemas hospitalarios y entrenamiento con datos locales. La adopción de estas tecnologías representa una oportunidad estratégica para mejorar la precisión, la seguridad y la eficiencia en el manejo quirúrgico del trauma vascular.

ANEXO. GLOSARIO DE TÉRMINOS TÉCNICOS

- *Aprendizaje automático (machine learning, ML)*: subárea de la inteligencia artificial que permite a los algoritmos aprender de datos y mejorar su rendimiento sin instrucciones explícitas.
- *Aprendizaje profundo (deep learning, DL)*: rama del aprendizaje automático basada en redes neuronales profundas utilizada para analizar grandes volúmenes de datos complejos, especialmente en imágenes médicas.
- *Área bajo la curva ROC (AUC)*: medida del rendimiento global de un modelo de clasificación binaria; valores cercanos a 1 reflejan excelente capacidad discriminativa.
- *Especificidad*: proporción de verdaderos negativos correctamente identificados; indica la habilidad del modelo para descartar falsos positivos.
- *GAN (red generativa adversaria)*: modelo de aprendizaje profundo que emplea dos redes en competencia (generador y discriminador) para crear datos sintéticos realistas.
- *Inteligencia artificial (IA)*: campo de la informática que desarrolla sistemas capaces de ejecutar tareas asociadas a la inteligencia humana, como el razonamiento, el aprendizaje y el reconocimiento de patrones.

- *Radiomics*: técnica que extrae características cuantitativas de imágenes médicas para alimentar modelos estadísticos o de aprendizaje automático.
- *Random forest*: método de ensamblaje de múltiples árboles de decisión que mejora la precisión y reduce el sobreajuste en modelos predictivos.
- *Red neuronal artificial (ANN)*: modelo computacional inspirado en el cerebro humano, compuesto por nodos organizados en capas, útil para la clasificación, la regresión y el reconocimiento de patrones.
- *Red neuronal convolucional (CNN)*: tipo de red neuronal diseñada para procesar datos con estructura de grilla, como imágenes, mediante filtros convolucionales que detectan características espaciales.
- *Sensibilidad (recall)*: proporción de verdaderos positivos correctamente identificados por el modelo; refleja la capacidad para detectar eventos clínicos importantes.
- *Validación cruzada (cross-validation)*: método estadístico para evaluar la capacidad predictiva de un modelo, dividiendo los datos en subconjuntos de entrenamiento y prueba.
- *XAI (inteligencia artificial explicable)*: conjunto de técnicas que permiten interpretar cómo un modelo de IA toma decisiones, promoviendo transparencia y aceptabilidad clínica.
- *XG Boost (extreme gradient boosting)*: algoritmo de aprendizaje supervisado basado en árboles de decisión, optimizado para velocidad y precisión en tareas de clasificación y regresión.

BIBLIOGRAFÍA

1. Kania TA, Patel H, Introna L, Kimyaghalam A, Arjmand S, Joutovsky B, et al. A Deep Learning-based Model to Predict Limb Amputation

- in Peripheral Vascular Trauma. J Vasc Surg 2023;77(6):e225. DOI: [10.1016/j.jvs.2023.03.310](https://doi.org/10.1016/j.jvs.2023.03.310)
2. Tran Z, Wilkinson MC, Guardamondo G, El-Farra MH, Peetz AB, Tomihama RT, et al. Narrative review on applications of artificial intelligence in vascular trauma. JVS-Vascular Insights 2025;100268. DOI: [10.1016/j.jvsvi.2025.100268](https://doi.org/10.1016/j.jvsvi.2025.100268)
 3. Knoedler L, Knoedler S, Allam O, Remy K, Miragall M, Safi AF, et al. Application possibilities of artificial intelligence in facial vascularized composite allotransplantation-a narrative review. Front Surg 2023;10. DOI: [10.3389/fsurg.2023.1266399](https://doi.org/10.3389/fsurg.2023.1266399)
 4. Seah J, Boeken T, Sapoval M, Goh GS. Prime Time for Artificial Intelligence in Interventional Radiology. Cardiovasc Intervent Radiol 2022;45(3):283-9. DOI: [10.1007/s00270-021-03044-4](https://doi.org/10.1007/s00270-021-03044-4)
 5. Martelli E, Capoccia L, Di Francesco M, Cavallo E, Pezzulla MG, Giudice G, et al. Current Applications and Future Perspectives of Artificial and Biomimetic Intelligence in Vascular Surgery and Peripheral Artery Disease. Biomimetics 2024;9(8):465. DOI: [10.3390/biomimetics908046](https://doi.org/10.3390/biomimetics908046)
 6. Li B, Eisenberg N, Beaton D, Lee DS, Al-Omran L, Wijesundera DN, et al. Predicting mortality risk following major lower extremity amputation using machine learning. J Vasc Surg 2025;82(2):617-31.e8. DOI: [10.1016/j.jvs.2025.03.198](https://doi.org/10.1016/j.jvs.2025.03.198)
 7. Adebayo O, Bhuiyan ZA, Ahmed Z. Exploring the effectiveness of artificial intelligence, machine learning and deep learning in trauma triage: A systematic review and meta-analysis. DIGITAL HEALTH 2023;20552076231205736. DOI: [10.1177/20552076231205736](https://doi.org/10.1177/20552076231205736)
 8. Bolourani S, Thompson D, Siskind S, Kalyon BD, Patel VM, Mussa FF. Cleaning Up the MESS: Can Machine Learning Be Used to Predict Lower Extremity Amputation after Trauma-Associated

- Arterial Injury? J Am Coll Surg 2021;232(1):102-13e4. DOI: [10.1016/j.jamcollsurg.2020.09.014](https://doi.org/10.1016/j.jamcollsurg.2020.09.014)
9. Bongurala AR, Save D, Virmani A, Kashyap R. Transforming Health Care with Artificial Intelligence: Redefining Medical Documentation. Mayo Clinic Proceedings: Digital Health 2024;2(3):342-7. DOI: [10.1016/j.mcpdig.2024.05.006](https://doi.org/10.1016/j.mcpdig.2024.05.006)
 10. Lee S, Kim HS. Prospect of Artificial Intelligence Based on Electronic Medical Records. J Lipid Atheroscler 2021;10(3):282. DOI: [10.12997/jla.2021.10.3.282](https://doi.org/10.12997/jla.2021.10.3.282)
 11. Toy J, Warren J, Wilhelm K, Putnam B, Whitfield D, Gausche-Hill M, et al. Use of artificial intelligence to support prehospital traumatic injury care: A scoping review. JACEP Open 2024;5(5):e13251. DOI: [10.1002/emp2.1325](https://doi.org/10.1002/emp2.1325)
 12. Ventura CA, Denton E, David J. Artificial Intelligence in Emergency Trauma Care: A Preliminary Scoping Review. MDER 2024;17:191-211. DOI: [10.2147/mders.s467146](https://doi.org/10.2147/mders.s467146)
 13. Arjomandi Rad A, Vardanyan R, Athanasiou T, Maessen J, Sardari Nia P. The ethical considerations of integrating artificial intelligence into surgery: a review. Interdisciplinary Cardiovasc Thorac Surg 2025;40(3). DOI: [10.1093/icvts/ivae192](https://doi.org/10.1093/icvts/ivae192)
 14. Li B, Feridooni T, Cuen-Ojeda C, Kishibe T, De Mestral C, Mamdani M, et al. Machine learning in vascular surgery: a systematic review and critical appraisal. npj Digit Med 2022;5(1). DOI: [10.1038/s41746-021-00552-y](https://doi.org/10.1038/s41746-021-00552-y)
 15. Knoedler L, Knoedler S, Allam O, Remy K, Miragall M, Safi AF, et al. Application possibilities of artificial intelligence in facial vascularized composite allotransplantation-a narrative review. Front Surg 2023;10:1266399. DOI: [10.3389/fsurg.2023.1266399](https://doi.org/10.3389/fsurg.2023.1266399)
 16. Van Sloun RJG, Solomon O, Bruce M, Khaing ZZ, Eldar YC, Mischi M. Deep Learning for Super-resolution Vascular Ultrasound Imaging [Internet]. ICASSP 2019 - 2019 IEEE International

Conference on Acoustics, Speech and Signal Processing (ICASSP).
IEEE; 2019. p. 1055-9. DOI: 10.1109/icassp.2019.8683813

