



Ciencia Latina Revista Científica Multidisciplinar, Ciudad de México, México.
ISSN 2707-2207 / ISSN 2707-2215 (en línea), septiembre-octubre 2026,
Volumen 10, Número 5.

https://doi.org/10.37811/cl_rem.v10i5

INTELIGENCIA ARTIFICIAL APLICADA A LA PLANIFICACIÓN PREOPERATORIA DE LA RECONSTRUCCIÓN MAMARIA AUTÓLOGA: REVISIÓN SISTEMÁTICA

**ARTIFICIAL INTELLIGENCE APPLIED TO PREOPERATIVE
PLANNING FOR AUTOLOGOUS BREAST
RECONSTRUCTION: A SYSTEMATIC REVIEW**

Mateo José González Dávila

Hospital General Docente Vicente Corral Moscoso, Ecuador

Santiago David Dutan Amay

Universidad de Cuenca, Ecuador

Diego Xavier Gutiérrez Ramón

Universidad de Cuenca, Ecuador

María José Arévalo Abad

Hospital General Docente Vicente Corral Moscoso, Ecuador

Diego Alejandro Espinoza Marin

Universidad de Cuenca, Ecuador

DOI: https://doi.org/10.37811/cl_rcm.v10i5.25945

Inteligencia Artificial aplicada a la Planificación Preoperatoria de la Reconstrucción Mamaria Autóloga: Revisión Sistemática

Mateo José González Dávila¹mateojgonzalezd@gmail.com<https://orcid.org/0009-0001-1303-4360>

Departamento de Cirugía, Hospital General

Docente Vicente Corral Moscoso

Ecuador

Santiago David Dutan Amaysantiago.dutana@ucuenca.edu.ec<https://orcid.org/0000-0002-3847-0554>

Universidad de Cuenca

Ecuador

Diego Xavier Gutiérrez Ramóndieg_gr_10@hotmail.com<https://orcid.org/0000-0001-6560-5711>

Universidad de Cuenca

Ecuador

María José Arévalo Abadmajo.231066@gmail.com<https://orcid.org/0009-0009-2151-8072>

Hospital General Docente Vicente Corral

Moscoso

Ecuador

Diego Alejandro Espinoza MarinDiego.espinozam@ucuenca.edu.ec<https://orcid.org/0009-0008-7758-9729>

Universidad de Cuenca

Ecuador

RESUMEN

Se realizó una revisión sistemática para sintetizar la evidencia clínica sobre las aplicaciones de inteligencia artificial (IA) en reconstrucción mamaria, con énfasis en la planificación preoperatoria de colgajos autólogos. Se siguieron las recomendaciones PRISMA 2020 y se realizaron búsquedas en PubMed/MEDLINE, Scopus y Cochrane Library entre 2015 y 2026. Se incluyeron estudios originales con resultados cuantitativos y, debido a la heterogeneidad metodológica, se efectuó una síntesis narrativa. Se analizaron 16 estudios. En reconstrucción autóloga, los algoritmos de visión computacional y aprendizaje profundo permitieron automatizar el mapeo vascular, reducir el tiempo de análisis y obtener mediciones anatómicas reproducibles, aunque persistieron limitaciones en vasos de pequeño calibre. Los modelos pronósticos mostraron un rendimiento variable para falla de colgajo, complicaciones y resultados reportados por las pacientes. Las redes neuronales aplicadas a evaluación estética alcanzaron alta precisión, mientras que los modelos de lenguaje mostraron utilidad en educación y apoyo a decisiones estructuradas. No se identificó evidencia prospectiva multicéntrica que demostrara reducción de necrosis, pérdida del colgajo o reintervenciones. La IA muestra utilidad como herramienta complementaria, pero aún requiere validación externa y estudios clínicos prospectivos antes de su incorporación rutinaria.

Palabras clave: inteligencia artificial, mamoplastia, colgajo perforante, aprendizaje automático, aprendizaje profundo

¹ Autor principal

Correspondencia: mateojgonzalezd@gmail.com

Artificial intelligence applied to preoperative planning for autologous breast reconstruction: a systematic review

ABSTRACT

A systematic review was conducted to synthesize the clinical evidence on artificial intelligence (AI) applications in breast reconstruction, with particular emphasis on preoperative planning for autologous flaps. The review followed PRISMA 2020 recommendations, and searches were performed in PubMed/MEDLINE, Scopus, and the Cochrane Library for studies published between 2015 and 2026. Original studies reporting quantitative outcomes were included, and a narrative synthesis was undertaken because of methodological heterogeneity. Sixteen studies were analyzed. In autologous reconstruction, computer vision and deep learning algorithms automated vascular mapping, reduced image-analysis time, and provided reproducible anatomical measurements, although performance remained limited for small-caliber vessels. Prognostic models showed variable performance for flap failure, complications, and patient-reported outcomes. Neural networks used for aesthetic assessment achieved high accuracy, whereas language models showed potential for patient education and support in structured decision-making. No prospective multicenter evidence demonstrated reductions in flap necrosis, flap loss, or reoperation attributable to AI. Current evidence supports AI as an adjunctive tool, but external validation and prospective clinical studies are still required before routine implementation.

Keywords: artificial intelligence, mammaplasty, perforator flap, machine learning, deep learning

Artículo recibido 15 julio 2023

Aceptado para publicación: 15 agosto 2023



INTRODUCCIÓN

La reconstrucción mamaria posterior a mastectomía puede realizarse con implantes, tejido autólogo o mediante técnicas combinadas. La elección depende de factores oncológicos, características anatómicas, antecedentes quirúrgicos y preferencias de la paciente. Entre las alternativas disponibles, la reconstrucción autóloga ofrece la posibilidad de utilizar tejido propio para restaurar el volumen y el contorno mamario, con resultados favorables en satisfacción y calidad de vida en comparación con algunas modalidades protésicas (Broyles et al., 2022; Garza et al., 2021).

Dentro de las técnicas autólogas, el colgajo de perforante de la arteria epigástrica inferior profunda (DIEP, deep inferior epigastric perforator) permite transferir piel y tejido adiposo del abdomen inferior preservando, en gran medida, el músculo recto abdominal. Su ejecución depende de una adecuada selección de las perforantes, cuya anatomía puede variar en calibre, localización y trayecto intramuscular; estas diferencias condicionan la estrategia quirúrgica y pueden influir en la perfusión del colgajo y en determinados resultados posoperatorios (Aravind et al., 2023; Saldanha et al., 2022).

La planificación preoperatoria mediante angiografía por tomografía computarizada, angiografía por resonancia magnética o ultrasonografía Doppler facilita la identificación de perforantes y la anticipación de su recorrido anatómico. La evidencia disponible sugiere que el mapeo preoperatorio puede reducir el tiempo operatorio y mejorar la concordancia entre los vasos identificados en las imágenes y aquellos seleccionados durante la cirugía, aunque persisten diferencias metodológicas entre los estudios y una calidad de evidencia variable (Kiely et al., 2021; Wade et al., 2018).

La interpretación convencional de estas imágenes requiere localizar los vasos, seguir su trayecto, estimar su calibre y establecer su relación con referencias anatómicas. Los sistemas computacionales y, más recientemente, los modelos de inteligencia artificial han comenzado a automatizar parte de este proceso. Estudios iniciales demostraron errores espaciales pequeños en la identificación de perforantes y una reducción importante del tiempo dedicado al análisis de la angio-TC; los modelos de aprendizaje profundo han ampliado estas aplicaciones hacia la segmentación vascular y la extracción automatizada de parámetros anatómicos útiles para la planificación del colgajo (Andrade et al., 2026; Araújo et al., 2019; Maita et al., 2024; Mavioso et al., 2020).



A pesar de estos avances, la evidencia continúa centrada principalmente en métricas de rendimiento técnico, como precisión, segmentación o tiempo de procesamiento, mientras que el efecto sobre desenlaces clínicos, tiempo de isquemia, reintervenciones, necrosis o pérdida del colgajo, sigue siendo menos claro (El Hachem & Ibrahim, 2026; Maita et al., 2024). Por ello, el objetivo de esta revisión sistemática fue sintetizar la evidencia disponible sobre la aplicación de inteligencia artificial en la planificación preoperatoria de la reconstrucción mamaria autóloga, con énfasis en el mapeo vascular, la identificación de perforantes, el rendimiento de los modelos y su posible repercusión sobre los resultados quirúrgicos.

METODOLOGÍA

Diseño de estudio

La revisión se estructuró conforme a la declaración PRISMA 2020, que organiza el reporte de la identificación, cribado, elegibilidad e inclusión de estudios y exige transparencia sobre las razones de exclusión a texto completo (Page et al., 2021).

Pregunta de investigación

En mujeres adultas candidatas a reconstrucción mamaria, especialmente reconstrucción autóloga con colgajos libres (P), ¿la utilización de IA, aprendizaje automático, aprendizaje profundo, visión computacional o herramientas algorítmicas de apoyo (I), comparada con evaluación convencional, lectura radiológica, decisión multidisciplinaria o referencia experta (C), mejora la precisión del mapeo, la eficiencia de la planificación, la predicción de resultados o la evaluación clínica (O)?

Componente	Definición
P – Población	Mujeres adultas candidatas a reconstrucción mamaria, con énfasis en colgajos autólogos DIEP/DIEAP.
I – Intervención	IA, machine learning, deep learning, computer vision, modelos generativos o sistemas computacionales automatizados aplicados a planificación, predicción o evaluación reconstructiva.
C – Comparación	Planificación manual, interpretación radiológica, modelos estadísticos convencionales, evaluación humana, comité multidisciplinario o estándar de referencia del estudio.
O – Resultados	Precisión/localización/segmentación; tiempo de análisis; AUC, sensibilidad/especificidad; concordancia; resultados BREAST-Q; complicaciones; desenlaces del colgajo.

Estrategia de búsqueda y fuentes de información

El protocolo definió PubMed/MEDLINE, Scopus y Cochrane Library como fuentes principales, con un periodo de publicación entre enero de 2015 y septiembre de 2026. Se combinaron términos: “Breast Reconstruction”, “Mammaplasty”, “DIEP”, “DIEAP”, “perforator flap”, “Artificial Intelligence”, “Machine Learning”, “Deep Learning”, “Computer Vision”, “Large Language Model”, “ChatGPT”, “Computed Tomography Angiography”, “preoperative planning”, “perforator mapping”, “outcome prediction”, “BREAST-Q” y “aesthetic assessment”.

Estrategia para PubMed: ((“Breast Reconstruction” OR “autologous breast reconstruction” OR DIEP OR DIEAP OR “perforator flap”) AND (“Artificial Intelligence” OR “Machine Learning” OR “Deep Learning” OR “computer vision” OR “large language model” OR ChatGPT) AND (planning OR mapping OR prediction OR complication* OR outcome* OR symmetry OR education)).

Estrategia para Scopus: TITLE-ABS-KEY (("breast reconstruction" OR "autologous breast reconstruction" OR "breast reconstructive surgery" OR mammaplasty) AND (DIEP OR DIEAP OR "deep inferior epigastric perforator" OR "deep inferior epigastric artery perforator" OR "perforator flap" OR "perforator flaps") AND ("artificial intelligence" OR "machine learning" OR "deep learning" OR "neural network" OR "neural networks" OR "computer vision" OR "computer aided" OR "computer-aided" OR automated OR automation) AND ("preoperative planning" OR "surgical planning" OR "vascular mapping" OR "perforator mapping" OR "perforator detection" OR "perforator identification" OR segmentation OR "vascular segmentation" OR volumetry OR "computed tomography angiography" OR CTA)) AND PUBYEAR > 2014 AND PUBYEAR < 2027

Estrategia para Cochrane Library: #1 ("breast reconstruction" OR "autologous breast reconstruction" OR DIEP OR DIEAP OR "deep inferior epigastric perforator"):ti,ab,kw

#2 ("artificial intelligence" OR "machine learning" OR "deep learning" OR "computer vision" OR automated OR segmentation OR algorithm*):ti,ab,kw

#3 #1 AND #2

Criterios de inclusión y exclusión

Se incluyeron estudios originales en seres humanos o conjuntos de imágenes clínicas vinculados con reconstrucción mamaria que evaluaran un sistema de IA o automatización algorítmica y comunicaran al


menos una medida cuantitativa de rendimiento, concordancia, tiempo, predicción o resultado clínico. Para el núcleo de planificación autóloga se exigió relación explícita con colgajos DIEP/DIEAP, mapeo vascular o selección de perforantes. Los modelos pronósticos, de resultados reportados por pacientes, simetría y apoyo a decisiones se conservaron como dominios complementarios porque forman parte del uso preoperatorio y de la evaluación reconstructiva.

Se excluyeron editoriales, cartas sin datos originales, resúmenes sin información suficiente, estudios sin vínculo con reconstrucción mamaria y trabajos puramente técnicos sin imágenes o pacientes clínicos. Las revisiones narrativas, sistemáticas y de alcance no se contabilizaron como evidencia primaria; se utilizaron para contextualizar y confrontar los hallazgos en la discusión.

Selección de estudios y extracción de datos

La información extraída de la búsqueda fue cargada en Rayyan, donde se realizó el cribado de estudios por dos revisores independientes, con resolución de discrepancias por consenso o mediante un tercer revisor. Para cada estudio se diseñó una matriz con autor, año, diseño, tamaño muestral, modalidad de datos, algoritmo, comparador, variable principal, rendimiento y limitaciones. Figura 1.

Figura 1. Diagrama de Flujo Prisma 2020 para selección de estudios.



Evaluación de la calidad metodológica y riesgo de sesgo

Para estudios de desarrollo o validación de modelos pronósticos se propuso PROBAST, que examina participantes, predictores, desenlace y análisis y permite separar problemas de aplicabilidad de los sesgos del modelo (Wolff et al., 2019).

Los estudios en los que el algoritmo se comportó como una prueba índice frente a una referencia radiológica o quirúrgica se consideraron compatibles con una evaluación adaptada mediante QUADAS-2, centrada en selección, prueba índice, estándar de referencia y flujo/tiempo (Whiting et al., 2011).

Síntesis de la evidencia

No se realizó metaanálisis debido a la heterogeneidad de los estudios, que resolvieron tareas diferentes y utilizaron métricas no intercambiables. Los resultados se agruparon en cuatro dominios: planificación vascular autóloga; predicción de complicaciones y resultados; evaluación estética; y apoyo generativo a educación y decisiones.

RESULTADOS

La búsqueda bibliográfica identificó 215 registros, de los cuales 71 procedieron de PubMed/MEDLINE, 31 de Scopus y 113 de Cochrane Library. Tras la eliminación de aproximadamente 48 registros duplicados, 167 artículos pasaron a la fase de cribado por título y resumen. En esta etapa se excluyeron cerca de 133 publicaciones por no cumplir con los criterios de elegibilidad, principalmente por no abordar aplicaciones de inteligencia artificial en reconstrucción mamaria, no corresponder a estudios originales o no evaluar desenlaces relacionados con planificación, predicción, evaluación estética o apoyo clínico. Posteriormente, 34 artículos fueron revisados a texto completo; 18 fueron excluidos por población, intervención o desenlaces no pertinentes, ausencia de datos suficientes o diseño no elegible. Finalmente, 16 estudios cumplieron los criterios de inclusión y fueron incorporados en la síntesis cualitativa de la revisión sistemática, de acuerdo con el proceso de selección establecido por PRISMA. De los 17 estudios primarios cuatro evaluaron mapeo o segmentación vascular en reconstrucción DIEP/DIEAP, seis desarrollaron modelos de predicción de complicaciones o resultados reportados por pacientes, tres analizaron evaluación estética automatizada, dos estudiaron apoyo generativo para educación o planificación, y uno evaluó termografía automatizada como extensión intraoperatoria;



algunos trabajos abarcaron más de un dominio.

La Tabla 1 resume los estudios originales incluidos. Los trabajos de mapeo vascular muestran una progresión desde visión computacional semiautomática hasta segmentación tridimensional con aprendizaje profundo; los modelos pronósticos, por su parte, presentan rendimientos muy variables y dependen con frecuencia de la distribución del evento y de la validación externa.

Tabla 1. Estudios primarios incluidos en la síntesis cualitativa

Estudio	Diseño / muestra	Aplicación de IA	Comparador	Hallazgo principal	Lectura metodológica
Andrade et al., 2026 (Andrade et al., 2026)	30 angio-TC; prueba final n=9	SAM 2, MedSAM-2 y nnInteractive con ajuste topológico	Segmentación experta	El ajuste fino del modelo incrementó el coeficiente Dice medio de 0,174 a 0,265 y permitió automatizar la estimación del trayecto intramuscular de las perforantes y de su distancia al ombligo.	Conjunto de prueba muy pequeño; utilidad anatómica aún por validar prospectivamente.
Mavioso et al., 2020 (Mavioso et al., 2020)	40 pacientes con planificación DIEP	Visión computacional y extracción de línea central	Mapeo manual + medidas intraoperatorias	La detección automatizada mostró errores de localización de aproximadamente 2–3 mm, sin repercusión relevante sobre la planificación de la disección, y redujo el tiempo de análisis de las imágenes en cerca de 2 horas por caso.	Aporta referencia quirúrgica; peor estimación de calibre en vasos <1,5 mm.
Araújo et al., 2019 (Araújo et al., 2019)	21 angio-TC de candidatas DIEAP	Tracking + optimización de coste para trayecto vascular	Anotación manual de radiólogo	El método alcanzó una alta precisión en la reconstrucción del trayecto vascular, con errores medios de 0,64 mm en el segmento subcutáneo y de 0,50 mm en el segmento intramuscular.	Muestra pequeña; validación técnica unicéntrica; buen referente anatómico.

O'Neill et al., 2020 (O'Neill et al., 2020)	1.012 reconstrucciones microvasculares; 12 fallas	Árboles de decisión + Cohorte retrospectiva; remuestreo para entrenamiento/prueba evento raro	El modelo alcanzó un AUC de 0,95 durante el entrenamiento, que disminuyó a 0,67 en el conjunto de prueba, evidenciando una menor capacidad de generalización ante datos no utilizados para su desarrollo.	Ilustra sobreajuste y efecto de desbalance de clases; falla de colgajo muy infrecuente.
Myung et al., 2021 (Myung et al., 2021)	568 reconstrucciones con colgajo abdominal	Redes neuronales y Modelos estadísticos y otros paquetes supervisados comparación entre algoritmos	El modelo Neuralnet presentó el mejor rendimiento predictivo. Las complicaciones del sitio donante se asociaron con la presencia de defecto fascial, diabetes, el uso de colgajos muscle-sparing y la administración de quimioterapia.	Cohorte retrospectiva; modelo condicionado a variables del centro.
Pfob et al., 2023 (Pfob et al., 2023)	1.921 mujeres; 11 centros	ML para resultados BREAST-Q a 1 año Validación entre centros	El modelo mostró un buen desempeño para identificar a las pacientes que presentarían cambios clínicamente significativos en calidad de vida y otros resultados informados por ellas mismas.	Fortaleza multicéntrica; desenlace subjetivo pero validado; depende de datos preoperatorios completos.
Pfob et al., 2021 (Pfob et al., 2021)	1.553 mujeres; 11 centros	Elastic net, XGBoost y red neuronal Validación externa en un centro no usado para entrenamiento	El modelo alcanzó una buena capacidad discriminativa para predecir cambios en la satisfacción mamaria a los 2 años, con AUC de 0,86–0,87 para mejoría y de 0,84–0,85 para disminución de la satisfacción.	Validación externa real; centrado en PRO y no en complicaciones quirúrgicas.

Naoum et al., 2022 (Naoum et al., 2022)	1.617 pacientes; varias técnicas reconstructivas	Nomogramas ML/LASSO para complicaciones con/sin radioterapia	Validación interna por cross-validation	El modelo alcanzó AUC de 0,73 para infección, 0,75 para contractura capsular, 0,76 para falla absoluta del implante y 0,68 para falla global, con un rendimiento predictivo variable según el desenlace evaluado.	Desempeño moderado; mezcla reconstrucción autóloga e implantaria.
Chen Y et al., 2023 (Chen et al., 2023)	Y. 209 mujeres; 406 muestras	Modelos supervisados + red neuronal	Partición entrenamiento/validación/prueba	La red neuronal alcanzó una exactitud de 0,82 y un AUC de 0,79 para predecir contractura capsular, lo que indica una capacidad discriminativa aceptable.	Tamaño moderado; reconstrucción implantaria; requiere validación externa.
Kenig et al., 2024 (Kenig, Monton Echeverria, & De La Ossa, 2024)	200 imágenes entrenamiento; 47 reconstrucciones prueba	CNN YOLOv3 para puntos anatómicos	Detección frente a anotación humana	El modelo detectó los límites mamarios, el complejo areola-pepón y la escotadura supraesternal con una tasa global de detección del 97,74 %, en un tiempo medio de 0,52 segundos por imagen.	Prueba pequeña; tarea estrecha y bien definida; no mide satisfacción ni desenlaces clínicos.
Kenig et al., 2024 (Kenig, Monton Echeverria, Chang Azancot, et al., 2024)	81 imágenes postreconstrucción	Red neuronal + BAS-Calc para simetría	Dos observadores humanos	El modelo identificó correctamente 399 de 405 referencias anatómicas (98,51 %) y realizó el análisis en un tiempo significativamente menor que la evaluación humana (0,92 frente a 14,09 segundos), con una fuerte correlación entre ambas mediciones.	Nivel de evidencia IV; evaluación fotográfica, no resultado clínico longitudinal.

Marcaccini et al., 2025 (Marcaccini et al., 2025)	Preguntas frecuentes en procedimientos mamarios	4	ChatGPT educación pacientes	para de Panel de cirujanos plásticos		En el contexto de reconstrucción mamaria, las respuestas generadas alcanzaron puntuaciones altas en relevancia, exactitud, claridad y empatía, con valores aproximados de 4,8–4,9 sobre 5, sin diferencias globales estadísticamente significativas entre los grupos comparados.	Evalúa calidad de respuesta, no comprensión ni conducta real de pacientes.
Cossu et al., 2025 (Cossu et al., 2025)	30 mujeres con cáncer de mama		Asistente generativo estructurado BREAST PLAN	Decisión del AI-multidisciplinario	comité	La concordancia fue muy alta para la indicación de neoadyuvancia ($\kappa=0,91$), moderada para la decisión quirúrgica ($\kappa=0,58$), y menor para el abordaje quirúrgico ($\kappa=0,43$), la reconstrucción mamaria ($\kappa=0,36$) y la terapia adyuvante ($\kappa=0,29$).	Muestra pequeña; la concordancia cae en decisiones sensibles a preferencia y contexto.
Chen J et al., 2026 (J. Chen et al., 2026)	4.776 pacientes: 2.687 MSKCC + 2.089 MROC		Cinco algoritmos ML para BREAST-Q a 1 año	Validación multicéntrica	externa	AUC bienestar físico abdomen; 0,97 satisfacción mamaria; 0,86 sexual; 0,79 0,74 psicosocial.	Uno de los ejemplos más sólidos de validación externa; predice PRO, no complicaciones del colgajo.



Kapila et al., 504 angio-TC; 55 3D Swin 2026 (Kapila segmentadas y 100 UNETR y CAD Anotación experta et al., 2026) para ombligo automatizado	El sistema localizó correctamente la región de interés (ROI) en el 100 % de los casos, con un tiempo medio de procesamiento de 28 ± 5 segundos y un error aproximado de 2 mm en la localización en submuestra; sin umbilical. La validación segmentación intraoperatoria vascular alcanzó externa. un coeficiente Dice de 0,58, que mejoró a 0,60 tras incorporar un entrenamiento orientado a preservar la continuidad de los vasos.
Cardenas De La Hoz et al., Termografía CNN para Anotación 2024 (De La dinámica durante segmentación de quirúrgica/segmentación Hoz et al., DIEP vasos/perfusión tradicional 2024)	La segmentación vascular alcanzó un coeficiente Dice aproximado de 0,8 a los 2 minutos y de 0,9 a los 4 minutos, complementaria; demostrando un no sustituye desempeño evidencia de progresivamente planificación mayor durante el CTA. análisis y capacidad de segmentación en tiempo real.
IA: inteligencia artificial; angio-TC/CTA: angiografía por tomografía computarizada; DIEP/DIEAP: deep inferior epigastric perforator; SAM 2: Segment Anything Model 2; MedSAM-2: modelo SAM adaptado a imágenes médicas; nnInteractive: modelo interactivo de segmentación 3D; AUC: área bajo la curva ROC; ML: aprendizaje automático; BREAST-Q: instrumento validado de resultados reportados por pacientes; PRO: resultados reportados por pacientes; XGBoost: Extreme Gradient Boosting; LASSO: Least Absolute Shrinkage and Selection Operator; CNN: red neuronal convolucional; YOLOv3: You Only Look Once, versión 3; BAS-Calc: Breast Aesthetic Scale Calculator; κ: coeficiente kappa; MSKCC: Memorial Sloan Kettering Cancer Center; MROC: Mastectomy Reconstruction Outcomes Consortium; ROI: región de interés; CAD: análisis asistido por computadora; 3D Swin UNETR: arquitectura tridimensional de segmentación basada en transformadores; Dice: coeficiente de similitud de segmentación.	

Planificación vascular de colgajos autólogos

Los estudios sobre planificación vascular muestran una evolución progresiva de estas herramientas. Los primeros trabajos utilizaron sistemas computacionales para seguir el trayecto de las perforantes ya identificadas en la angio-TC y disminuir el tiempo necesario para analizar las imágenes. En investigaciones más recientes, especialmente las publicadas en 2026, se incorporaron modelos capaces de realizar segmentación vascular tridimensional de forma automática y calcular datos útiles para la

cirugía, como la longitud del trayecto intramuscular y la distancia de la perforante al ombligo. Sin embargo, el rendimiento de estos sistemas disminuye cuando los vasos son muy pequeños, presentan trayectos complejos o cuando el algoritmo debe reconstruir de forma continua todo el recorrido vascular. Desde el punto de vista clínico, Mavioso et al. aportaron una de las comparaciones más cercanas con los hallazgos quirúrgicos. Posteriormente, Andrade et al. y Kapila et al. ampliaron el grado de automatización del análisis vascular (Andrade et al., 2026; Kapila et al., 2026; Mavioso et al., 2020). A pesar de estos avances, todavía no se ha demostrado de forma consistente que la perforante seleccionada por el algoritmo sea la misma que finalmente elige el cirujano, ni que el uso de estas herramientas reduzca el tiempo de isquemia, la necrosis del colgajo o la necesidad de una nueva intervención. Por esta razón, los resultados de precisión y segmentación deben considerarse indicadores del funcionamiento técnico del modelo y no una demostración directa de mejores resultados quirúrgicos.

Predicción de complicaciones y resultados reportados por pacientes

Los modelos pronósticos mostraron resultados variables según el desenlace evaluado. La predicción de falla del colgajo fue especialmente difícil por tratarse de un evento poco frecuente. En el estudio de O'Neill et al., el buen desempeño observado durante el entrenamiento disminuyó de forma marcada al aplicar el modelo al conjunto de prueba, lo que sugiere una capacidad limitada para mantener el mismo rendimiento en nuevos pacientes (O'Neil & Gilmour, 2003). En cambio, los modelos diseñados para predecir resultados del BREAST-Q obtuvieron un desempeño más consistente, favorecido por muestras de mayor tamaño y, en los estudios más recientes, por la validación en diferentes centros (J. Chen et al., 2026; Pfoh et al., 2021, 2023). Algunos de estos modelos lograron una buena discriminación para dominios específicos relacionados con satisfacción y calidad de vida.

En los estudios centrados en reconstrucción con implantes, la capacidad para anticipar complicaciones fue moderada. Estos resultados pueden ser útiles para identificar pacientes con mayor riesgo, aunque no deben trasladarse directamente a la reconstrucción autóloga, ya que los factores relacionados con cada técnica son diferentes. Los predictores también variaron según el desenlace analizado: la radioterapia y determinadas características del implante tuvieron mayor peso en la predicción de contractura capsular o falla del implante, mientras que los modelos orientados a resultados reportados por las pacientes estuvieron más relacionados con las puntuaciones preoperatorias del BREAST-Q, el tipo de

reconstrucción, el índice de masa corporal, la edad y el momento de administración de la radioterapia (Y. Chen et al., 2023; Naoum et al., 2022).

Evaluación estética y simetría

Las aplicaciones de inteligencia artificial dirigidas a la evaluación estética mostraron un desempeño elevado en la identificación automática de referencias anatómicas mamarias. Los estudios de Kenig et al. alcanzaron tasas de detección superiores al 97 % y tiempos de procesamiento inferiores a un segundo, lo que podría facilitar mediciones más rápidas y reproducibles de la simetría mamaria frente a la evaluación manual (Kenig, Monton Echeverria, Chang Azancot, et al., 2024; Kenig, Monton Echeverria, & De La Ossa, 2024).

La concordancia observada entre las mediciones automatizadas y las realizadas por evaluadores humanos respalda su utilidad como herramienta objetiva para cuantificar características morfológicas. Sin embargo, estos resultados proceden de muestras pequeñas y del análisis de fotografías bidimensionales, por lo que no permiten asumir que una mejor puntuación de simetría refleje necesariamente mayor satisfacción con la reconstrucción, mejor imagen corporal o mejor calidad de vida de las pacientes.

Modelos generativos para educación y apoyo a decisiones

Los estudios que evaluaron modelos de lenguaje mostraron un comportamiento diferente al observado con las herramientas de visión computacional. Cuando se utilizaron para responder preguntas frecuentes o proporcionar información sobre reconstrucción mamaria, las respuestas recibieron valoraciones favorables por parte de especialistas en aspectos como claridad, exactitud y relevancia (Cossu et al., 2025; Marcaccini et al., 2025).

El desempeño fue menos uniforme cuando los modelos se aplicaron a decisiones clínicas más complejas. En el estudio de Cossu et al., la concordancia con el comité multidisciplinario fue mayor para decisiones basadas en criterios relativamente estructurados, como la indicación de tratamiento neoadyuvante, y disminuyó en aspectos como el tipo de cirugía, el abordaje reconstructivo y otras decisiones dependientes del contexto clínico (Cossu et al., 2025).

Estos hallazgos sugieren que los modelos de lenguaje pueden desenvolverse mejor en tareas con criterios definidos y menor variabilidad interpretativa. En cambio, su rendimiento parece disminuir cuando la



decisión exige integrar preferencias de la paciente, características anatómicas, hallazgos visuales y juicio clínico individualizado, elementos que no siempre pueden representarse de forma completa mediante información textual estructurada.

Riesgo de sesgo y aplicabilidad

La principal debilidad metodológica de los estudios incluidos fue la limitada validación externa. En los trabajos basados en imágenes fueron frecuentes las muestras pequeñas, procedentes de un solo centro y evaluadas mediante particiones internas del mismo conjunto de datos. En los modelos pronósticos, las principales fuentes de sesgo estuvieron relacionadas con el bajo número de eventos, el desequilibrio entre clases y la posibilidad de sobreajuste. En contraste, los estudios multicéntricos con validación en poblaciones independientes, especialmente aquellos orientados a resultados medidos mediante BREAST-Q, ofrecieron mayor respaldo para valorar la capacidad de generalización de los modelos.

En los estudios que utilizaron modelos generativos, las limitaciones estuvieron asociadas principalmente con el reducido número de casos, la influencia de la formulación del prompt, la ausencia de seguimiento clínico y la dificultad para incorporar aspectos individuales como las preferencias de la paciente o el contexto específico de cada decisión reconstructiva. Debido a la diversidad de diseños y objetivos, no se utilizó una única puntuación global de calidad. La evaluación del riesgo de sesgo se realizó con herramientas acordes con cada tipo de estudio, como PROBAST para modelos predictivos y QUADAS-2 para estudios de rendimiento diagnóstico o de segmentación.

En la Tabla 2 se presenta la evaluación del riesgo de sesgo de los estudios incluidos, considerando el tipo de diseño, la herramienta metodológica aplicada y las principales limitaciones identificadas en cada investigación.

Tabla 2. Evaluación del riesgo de sesgo de los estudios incluidos

Estudio	Tipo de estudio	Herramienta de evaluación	Principales aspectos metodológicos	Riesgo global
Andrade et al., 2026	Desarrollo/validación de segmentación	QUADAS-2 adaptado	Muestra y conjunto de prueba pequeños; sin validación externa	Alto
Mavioso et al., 2020	Validación de herramienta de imagen	QUADAS-2 adaptado	Comparación intraoperatoria, pero muestra unicéntrica	Moderado
Araújo et al., 2019	Validación técnica	QUADAS-2 adaptado	Muestra pequeña; referencia radiológica; sin validación externa	Alto
O'Neill et al., 2020	Modelo pronóstico retrospectivo	PROBAST/PROBAST+AI	Muy pocos eventos; desbalance de clases; menor rendimiento en prueba	Alto
Myung et al., 2021	Modelo pronóstico retrospectivo	PROBAST/PROBAST+AI	Validación interna; estudio unicéntrico	Alto
Pfob et al., 2023	Modelo pronóstico multicéntrico	PROBAST/PROBAST+AI	Amplia muestra y validación entre centros	Bajo–moderado
Pfob et al., 2021	Modelo pronóstico multicéntrico	PROBAST/PROBAST+AI	Validación externa; PRO como desenlace	Bajo–moderado
Naoum et al., 2022	Modelo predictivo retrospectivo	PROBAST/PROBAST+AI	Validación interna; población reconstructiva heterogénea	Moderado–alto
Chen Y et al., 2023	Modelo predictivo	PROBAST/PROBAST+AI	Muestra moderada y ausencia de validación externa	Alto
Kenig et al., 2024	Validación de visión computacional	QUADAS-2 adaptado	Conjunto de prueba pequeño	Alto
Kenig et al., 2024	Validación de evaluación estética	QUADAS-2 adaptado	Muestra limitada; comparación con observadores humanos	Moderado–alto
Marcaccini et al., 2025	Evaluación de modelo generativo	Criterios metodológicos adaptados	Evaluación subjetiva; dependencia del prompt	Alto
Cossu et al., 2025	Concordancia IA-comité	QUADAS-2 adaptado	Solo 30 pacientes; unicéntrico	Alto
Chen J et al., 2026	Modelo pronóstico multicéntrico	PROBAST/PROBAST+AI	Cohorte amplia y validación externa	Bajo–moderado
Kapila et al., 2026	Segmentación vascular mediante IA	QUADAS-2 adaptado	Base amplia, pero referencia manual en submuestra; sin validación externa	Moderado–alto
Cardenas De La Hoz et al., 2024	Segmentación intraoperatoria	QUADAS-2 adaptado	Muestra limitada; validación principalmente técnica	Alto

Nota. La evaluación del riesgo de sesgo se realizó de acuerdo con el diseño de cada estudio. Los modelos predictivos se valoraron mediante PROBAST/PROBAST+AI y los estudios de detección, segmentación o concordancia frente a una referencia experta mediante QUADAS-2 adaptado. Debido a la heterogeneidad metodológica, no se calculó una puntuación global común para todos los estudios.

DISCUSIÓN

Los estudios revisados muestran que la IA ya puede ejecutar tareas concretas de reconstrucción mamaria, pero su rendimiento no es uniforme, los modelos que predicen desenlaces quirúrgicos presentan una dispersión considerable y una revisión sistemática reciente encontró una mediana de AUC de 0,71 entre 19 modelos, por lo que nuestros hallazgos coinciden con Rosenbloom et al. en que la madurez técnica depende más del problema y del diseño de validación que de la etiqueta “IA”



(Rosenbloom et al., 2026).

En planificación microquirúrgica, la progresión desde el seguimiento semiautomático de vasos hasta modelos profundos tridimensionales coincide con la revisión de Shadid et al., que describe una transición rápida hacia segmentación, mapeo de perforantes y apoyo individualizado; ambos análisis, sin embargo, señalan que la evidencia sigue dominada por series retrospectivas de un solo centro (Shadid et al., 2025).

La concentración de estudios en la fase preoperatoria también coincide con la revisión de alcance de El Hachem e Ibrahim, donde 28 de 40 trabajos originales correspondieron a aplicaciones preoperatorias, mientras las herramientas intraoperatorias y posoperatorias fueron menos frecuentes; esa distribución ayuda a explicar por qué existen más datos sobre predicción o planificación que sobre desenlaces quirúrgicos posteriores (El Hachem & Ibrahim, 2026).

Los resultados pronósticos deben interpretarse junto con herramientas clínicas simples: Joo y Giatsidis encontraron que un índice de fragilidad elevado se asociaba de manera consistente con complicaciones, readmisión y retorno al quirófano en reconstrucción autóloga, lo que contrasta con la idea de que un algoritmo complejo necesariamente supera a una variable clínica bien seleccionada y refuerza la necesidad de comparar los modelos con baselines clínicos útiles (Joo & Giatsidis, 2022).

La automatización de medidas estéticas coincide con la aceptación observada por Kenig et al., quienes comunicaron altos niveles de comodidad con el uso de IA cuando esta estaba mediada por un médico; el mismo estudio mostró una pérdida de confianza cuando se planteaba una interacción sin supervisión profesional, de modo que la precisión técnica de una medición no elimina la necesidad de contextualizarla con la paciente (Kenig, Muntaner Vives, & Monton Echeverria, 2024).

En educación, nuestros resultados favorables para respuestas estructuradas contrastan con el trabajo de Xie et al., en el que ChatGPT produjo explicaciones pertinentes pero superficiales y llegó a generar referencias inexistentes; la diferencia indica que la utilidad clínica de un modelo de lenguaje depende tanto de la tarea como del mecanismo de verificación de sus salidas (Xie et al., 2023).

Ese contraste se repite fuera de la consulta reconstructiva: Gomez-Cabello et al. observaron respuestas posoperatorias globalmente precisas en varios modelos de lenguaje, pero con diferencias en legibilidad, comprensión y capacidad de orientar acciones, lo que coincide con nuestra conclusión de que la calidad



debe evaluarse por dimensiones y no mediante una impresión general de “buena respuesta” (Gomez-Cabello et al., 2024).

Gorgy et al. plantean que la aplicación de la inteligencia artificial en cirugía reconstructiva abarca distintos campos, entre ellos los modelos predictivos, la visión computacional, el procesamiento del lenguaje y la robótica. Nuestros hallazgos coinciden con esta diversidad de aplicaciones; sin embargo, muestran la necesidad de diferenciar con claridad los resultados técnicos, como el coeficiente Dice, la exactitud o el tiempo de procesamiento de los desenlaces clínicos como necrosis, pérdida del colgajo, reintervención o calidad de vida, ya que una mejora en el rendimiento del algoritmo no implica necesariamente un beneficio clínico para la paciente (Gorgy et al., 2026).

Las limitaciones observadas también coinciden con lo señalado por Mansoor e Ibrahim, quienes advierten dificultades relacionadas con la privacidad de los datos, el sesgo algorítmico, la atribución de responsabilidades y la validación de sistemas propietarios. En nuestra revisión, sin embargo, los problemas más inmediatos para trasladar estos modelos a la práctica clínica fueron la escasa validación externa y la heterogeneidad de las cohortes, más que las limitaciones técnicas de los propios algoritmos (Mansoor & Ibrahim, 2025).

Shen et al. consideran que la IA puede integrarse en planificación, visualización, perfusión y seguimiento, pero subrayan la necesidad de validación clínica a gran escala; nuestros hallazgos coinciden con esa dirección y añaden que, en el caso específico del DIEP, el siguiente estudio decisivo no debería limitarse a mejorar el Dice, sino comparar la perforante propuesta por el algoritmo con la selección radiológica, la elección intraoperatoria y los resultados del colgajo (Shen et al., 2025).

Peet et al. señalan que las aplicaciones de inteligencia artificial centradas en la paciente han aumentado en áreas como la predicción de resultados reportados por las pacientes, la evaluación estética y la educación en salud. Nuestros hallazgos coinciden con esta tendencia; sin embargo, los buenos valores de discriminación alcanzados por algunos modelos para predecir cambios en los dominios del BREAST-Q no demuestran que el uso de la inteligencia artificial mejore por sí mismo la calidad de vida o la satisfacción de las pacientes. Aún es necesario establecer si incorporar estas predicciones a la práctica clínica modifica la toma de decisiones y se traduce en mejores resultados reconstructivos (Peet et al., 2025).



Fortalezas de la revisión

Entre las fortalezas de esta revisión destaca la clasificación de las aplicaciones de inteligencia artificial en cuatro grupos: análisis anatómico, predicción clínica, evaluación estética y modelos de lenguaje. Esta estructura permite valorar los resultados dentro de su contexto metodológico, evitando equiparar indicadores que responden a objetivos diferentes. A su vez, ayuda a reconocer qué herramientas presentan mayor cercanía con la práctica clínica y cuáles aún requieren validación antes de una implementación más amplia.

Limitaciones

La heterogeneidad impidió un metaanálisis. Las diferencias abarcaron población, modalidad de imagen, fase clínica, algoritmo, estándar de referencia y medida de rendimiento. En varios artículos, el tamaño efectivo del conjunto de prueba fue pequeño aun cuando la base total de imágenes era mayor, y la ausencia de validación externa limita la inferencia sobre rendimiento en otros escáneres, centros y poblaciones.

Implicaciones clínicas y para investigación

Con la evidencia disponible, la aplicación más respaldada de la inteligencia artificial es como herramienta de apoyo clínico. Su utilidad actual se concentra en agilizar el mapeo vascular, estandarizar mediciones, estimar riesgos y organizar información que pueda facilitar la planificación y la discusión terapéutica. En reconstrucción mamaria autóloga, los algoritmos aplicados a la angio-TC deberían considerarse, por ahora, como una segunda lectura o un complemento para la preparación quirúrgica, hasta que estudios prospectivos demuestren su capacidad para igualar o mejorar la selección de perforantes y los resultados del colgajo frente a la planificación convencional.

Las futuras investigaciones deberían mejorar, sobre todo, la calidad de la validación. Es necesario separar con claridad las fases de desarrollo y prueba externa, registrar previamente el modelo y el plan de análisis, y reportar no solo medidas de discriminación, sino también calibración y desempeño en poblaciones independientes. En el caso de la planificación con colgajo DIEP, sería especialmente útil evaluar la concordancia entre la perforante sugerida por el algoritmo y la finalmente utilizada en cirugía, así como el tiempo de disección e isquemia, la lesión muscular o nerviosa, la necesidad de reexploración vascular, la necrosis parcial o pérdida total del colgajo y los resultados reportados por las pacientes

mediante instrumentos como BREAST-Q.

CONCLUSIONES

La inteligencia artificial ya ofrece aplicaciones concretas en reconstrucción mamaria, sobre todo para el análisis de imágenes, la predicción de resultados y la evaluación objetiva de la simetría. En la reconstrucción autóloga con colgajo DIEP, los algoritmos aplicados a la angio-TC pueden reducir el tiempo necesario para el mapeo vascular y facilitar la identificación y caracterización de las perforantes. Sin embargo, la evidencia disponible todavía no permite afirmar que su uso mejore la selección final del vaso, disminuya el tiempo de isquemia o reduzca complicaciones como necrosis, reexploración o pérdida del colgajo.

Para el cirujano plástico, estas herramientas tienen actualmente mayor utilidad como complemento de la planificación que como sustituto de la valoración radiológica y del juicio intraoperatorio. Los modelos con mejor validación pueden aportar información útil para estimar riesgos y anticipar resultados reportados por las pacientes, pero su desempeño depende de la población y de los datos utilizados para desarrollarlos. Antes de incorporarlos de forma rutinaria, se necesitan estudios prospectivos y multicéntricos que comparen las recomendaciones del algoritmo con la decisión quirúrgica real y evalúen desenlaces directamente relevantes para la práctica reconstructiva.

Financiación

La presente revisión sistemática fue financiada por los autores.

Conflicto de interés

Los autores declaran no tener conflicto de intereses.

Disponibilidad de datos, códigos y otros materiales

Cualquier información adicional requerida puede ser solicitada a los autores mediante correo electrónico.

Declaración sobre el uso de inteligencia artificial

Durante la preparación del manuscrito se utilizó una herramienta de inteligencia artificial generativa como apoyo para mejorar la redacción, claridad y organización lingüística de un borrador elaborado previamente por los autores. La selección de los estudios, extracción e interpretación de los datos, evaluación metodológica y elaboración de las conclusiones fueron realizadas por los autores. Todo el



contenido generado o modificado con apoyo de inteligencia artificial fue posteriormente revisado, corregido y aprobado por los autores, quienes asumen la responsabilidad íntegra del contenido final del manuscrito.

REFERENCIAS BIBLIOGRÁFICAS

- Andrade, M., Loução, N., Pinto, D., Marques, T., Vigário, R., Gouveia, P., & Santinha, J. (2026). AI-based planning for DIEAP flap procedures: Exploring foundation models for artery perforators analysis. *Frontiers in Medicine*, 13, 1757637. <https://doi.org/10.3389/fmed.2026.1757637>
- Araújo, R. J., Garrido, V., Baraças, C. A., Vasconcelos, M. A., Mavioso, C., Anacleto, J. C., Cardoso, M. J., & Oliveira, H. P. (2019). Computer aided detection of deep inferior epigastric perforators in computed tomography angiography scans. *Computerized Medical Imaging and Graphics*, 77, 101648. <https://doi.org/10.1016/j.compmedimag.2019.101648>
- Aravind, P., Colakoglu, S., Bhoopalam, M., Ibrahim, A., Mathes, D., Kaoutzanis, C., Mureau, M., & Reddy, S. (2023). Perforator Characteristics and Impact on Postoperative Outcomes in DIEP Flap Breast Reconstruction: A Systematic Review and Meta-Analysis. *Journal of Reconstructive Microsurgery*, 39(02), 138-147. <https://doi.org/10.1055/s-0042-1750124>
- Broyles, J. M., Balk, E. M., Adam, G. P., Cao, W., Bhuma, M. R., Mehta, S., Dominici, L. S., Pusic, A. L., & Saldanha, I. J. (2022). Implant-based versus Autologous Reconstruction after Mastectomy for Breast Cancer: A Systematic Review and Meta-analysis. *Plastic and Reconstructive Surgery - Global Open*, 10(3), e4180. <https://doi.org/10.1097/GOX.00000000000004180>
- Chen, J., Gabay, A., Boe, L. A., Shammas, R. L., Stern, C., Pusic, A., Mehrara, B. J., Gibbons, C., & Nelson, J. A. (2026). Machine Learning Accurately Predicts Patient-reported Outcomes 1 Year After Breast Reconstruction. *Annals of Surgery*, 284(1), 176-183. <https://doi.org/10.1097/SLA.00000000000006688>
- Chen, Y., Wang, M. L., Black, G. G., Qin, N., Zhou, G., Bernstein, J. L., Chinta, M., & Otterburn, D. M. (2023). Machine-Learning Prediction of Capsular Contraction after Two-Stage Breast Reconstruction. *JPRAS Open*, 38, 1-13. <https://doi.org/10.1016/j.jpra.2023.07.008>
- Cossu, M., Cuniolo, L., Diaz, R., Oliva, M., Cornacchia, C., Murelli, F., Depaoli, F., Gipponi, M., Margarino, C., Boccardo, C., Franchelli, S., Pesce, M., Allievi, R., D'Agraves, A. C., Abdallah,



- S., & Fregatti, P. (2025). BREAST AI-PLAN: Prompt-Driven AI Assistance for Breast Surgery Planning – A Retrospective Single-center Study. *In Vivo*, 39(6), 3271-3277.
<https://doi.org/10.21873/invivo.14126>
- De La Hoz, E. C., Verstockt, J., Verspeek, S., Clarys, W., Thiessen, F. E. F., Tondy, T., Tjalma, W. A. A., Steenackers, G., & Vanlanduit, S. (2024). Automated thermographic detection of blood vessels for DIEP flap reconstructive surgery. *International Journal of Computer Assisted Radiology and Surgery*, 19(9), 1733-1741. <https://doi.org/10.1007/s11548-024-03199-8>
- El Hachem, T., & Ibrahim, A. E. (2026). Artificial Intelligence in Breast Reconstruction: A Scoping Review of Pre-, Intra-, and Postoperative Applications. *Plastic and Reconstructive Surgery - Global Open*, 14(5), e7706. <https://doi.org/10.1097/GOX.00000000000007706>
- Garza, R., Ochoa, O., & Chrysopoulou, M. (2021). Post-mastectomy Breast Reconstruction with Autologous Tissue: Current Methods and Techniques. *Plastic and Reconstructive Surgery - Global Open*, 9(2), e3433. <https://doi.org/10.1097/GOX.00000000000003433>
- Gomez-Cabello, C. A., Borna, S., Pressman, S. M., Haider, S. A., Sehgal, A., Leibovich, B. C., & Forte, A. J. (2024). Artificial Intelligence in Postoperative Care: Assessing Large Language Models for Patient Recommendations in Plastic Surgery. *Healthcare*, 12(11), 1083.
<https://doi.org/10.3390/healthcare12111083>
- Gorgy, A., Xu, H. H., Hawary, H. E., Nepon, H., Lee, J., & Vorstenbosch, J. (2026). Integrating AI into Breast Reconstruction Surgery: Exploring Opportunities, Applications, and Challenges. *Plastic Surgery*, 34(1), 37-46. <https://doi.org/10.1177/22925503241292349>
- Joo, A., & Giatsidis, G. (2022). In Autologous Breast Reconstruction, Frailty Is a More Accurate Predictor of Postoperative Complications: A Retrospective Cohort Analysis. *Plastic & Reconstructive Surgery*, 150, 82S-94S. <https://doi.org/10.1097/PRS.00000000000009531>
- Kapila, A. K., Lamtenzan Marcos, D., Ceranka, J., Brussaard, C., Boonen, P. T., Ledegen, L., Vandemeulebroucke, J., & Hamdi, M. (2026). Automated CTA-based perforator mapping for DIEP flap planning in breast cancer reconstruction. *Artificial Intelligence Surgery*, 6(2), 255-267. <https://doi.org/10.20517/ais.2026.01>



- Kenig, N., Monton Echeverria, J., Chang Azancot, L., & De La Ossa, L. (2024). A Novel Artificial Intelligence Model for Symmetry Evaluation in Breast Cancer Patients. *Aesthetic Plastic Surgery*, 48(7), 1500-1507. <https://doi.org/10.1007/s00266-023-03554-1>
- Kenig, N., Monton Echeverria, J., & De La Ossa, L. (2024). Identification of Key Breast Features Using a Neural Network: Applications of Machine Learning in the Clinical Setting of Plastic Surgery. *Plastic & Reconstructive Surgery*, 153(2), 273e-280e. <https://doi.org/10.1097/PRS.00000000000010603>
- Kenig, N., Muntaner Vives, A., & Monton Echeverria, J. (2024). Is My Doctor Human? Acceptance of AI among Patients with Breast Cancer. *Plastic and Reconstructive Surgery - Global Open*, 12(10), e6257. <https://doi.org/10.1097/GOX.00000000000006257>
- Kiely, J., Kumar, M., & Wade, R. G. (2021). The accuracy of different modalities of perforator mapping for unilateral DIEP flap breast reconstruction: A systematic review and meta-analysis. *Journal of Plastic, Reconstructive & Aesthetic Surgery*, 74(5), 945-956. <https://doi.org/10.1016/j.bjps.2020.12.005>
- Maita, K. C., Avila, F. R., Torres-Guzman, R. A., Garcia, J. P., De Sario Velasquez, G. D., Borna, S., Brown, S. A., Haider, C. R., Ho, O. S., & Forte, A. J. (2024). The usefulness of artificial intelligence in breast reconstruction: A systematic review. *Breast Cancer*, 31(4), 562-571. <https://doi.org/10.1007/s12282-024-01582-6>
- Mansoor, M., & Ibrahim, A. F. (2025). The Transformative Role of Artificial Intelligence in Plastic and Reconstructive Surgery: Challenges and Opportunities. *Journal of Clinical Medicine*, 14(8), 2698. <https://doi.org/10.3390/jcm14082698>
- Marcaccini, G., Susini, P., Xie, Y., Cuomo, R., Pozzi, M., Grimaldi, L., Rozen, W. M., & Seth, I. (2025). Enhancing patient education in breast surgery: Artificial intelligence-powered guidance for mastopexy, augmentation, reduction, and reconstruction. *Translational Breast Cancer Research*, 6, 12-12. <https://doi.org/10.21037/tbcr-24-67>
- Mavioso, C., Araújo, R. J., Oliveira, H. P., Anacleto, J. C., Vasconcelos, M. A., Pinto, D., Gouveia, P. F., Alves, C., Cardoso, F., Cardoso, J. S., & Cardoso, M. J. (2020). Automatic detection of perforators for microsurgical reconstruction. *The Breast*, 50, 19-24.



<https://doi.org/10.1016/j.breast.2020.01.001>

- Myung, Y., Jeon, S., Heo, C., Kim, E.-K., Kang, E., Shin, H.-C., Yang, E.-J., & Jeong, J. H. (2021). Validating machine learning approaches for prediction of donor related complication in microsurgical breast reconstruction: A retrospective cohort study. *Scientific Reports*, 11(1), 5615. <https://doi.org/10.1038/s41598-021-85155-z>
- Naoum, G. E., Ho, A. Y., Shui, A., Salama, L., Goldberg, S., Arafat, W., Winograd, J., Colwell, A., Smith, B. L., & Taghian, A. G. (2022). Risk of Developing Breast Reconstruction Complications: A Machine-Learning Nomogram for Individualized Risk Estimation with and without Postmastectomy Radiation Therapy. *Plastic & Reconstructive Surgery*, 149(1), 1e-12e. <https://doi.org/10.1097/PRS.00000000000008635>
- O'Neil, B., & Gilmour, D. (2003). Approach to urinary incontinence in women. Diagnosis and management by family physicians. *Canadian Family Physician Medecin De Famille Canadien*, 49, 611-618.
- O'Neill, A. C., Yang, D., Roy, M., Sebastianpillai, S., Hofer, S. O. P., & Xu, W. (2020). Development and Evaluation of a Machine Learning Prediction Model for Flap Failure in Microvascular Breast Reconstruction. *Annals of Surgical Oncology*, 27(9), 3466-3475. <https://doi.org/10.1245/s10434-020-08307-x>
- Page, M. J., Moher, D., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... McKenzie, J. E. (2021). PRISMA 2020 explanation and elaboration: Updated guidance and exemplars for reporting systematic reviews. *BMJ (Clinical Research Ed.)*, 372, n160. <https://doi.org/10.1136/bmj.n160>
- Peet, B. M., Sidoti, A., Allen, R. J., Nelson, J. A., & Graziano, F. (2025). Artificial Intelligence in Breast Reconstruction: Enhancing Surgical Planning, Aesthetic Outcomes, and Patient-Centered Care. *Journal of Clinical Medicine*, 14(21), 7821. <https://doi.org/10.3390/jcm14217821>
- Pfob, A., Mehrara, B. J., Nelson, J. A., Wilkins, E. G., Pusic, A. L., & Sidey-Gibbons, C. (2021). Machine learning to predict individual patient-reported outcomes at 2-year follow-up for women



- undergoing cancer-related mastectomy and breast reconstruction (INSPIRED-001). *The Breast*, 60, 111-122. <https://doi.org/10.1016/j.breast.2021.09.009>
- Pfob, A., Mehrara, B. J., Nelson, J. A., Wilkins, E. G., Pusic, A. L., & Sidey-Gibbons, C. (2023). Towards Patient-centered Decision-making in Breast Cancer Surgery: Machine Learning to Predict Individual Patient-reported Outcomes at 1-year Follow-up. *Annals of Surgery*, 277(1), e144-e152. <https://doi.org/10.1097/SLA.0000000000004862>
- Rosenbloom, A., Gasbeck, T., Mamoun, L., Shah, N., Nanda, A., & Lee, G. (2026). Predicting Surgical Outcomes in Breast Reconstruction With Machine Learning: A Systematic Review. *Annals of Plastic Surgery*, 96(4S), S159-S172. <https://doi.org/10.1097/SAP.0000000000004667>
- Saldanha, I. J., Broyles, J. M., Adam, G. P., Cao, W., Bhuma, M. R., Mehta, S., Pusic, A. L., Dominici, L. S., & Balk, E. M. (2022). Autologous Breast Reconstruction after Mastectomy for Breast Cancer: A Systematic Review. *Plastic and Reconstructive Surgery - Global Open*, 10(3), e4181. <https://doi.org/10.1097/GOX.0000000000004181>
- Shadid, O., Seth, I., Cuomo, R., Rozen, W. M., & Marcaccini, G. (2025). Artificial Intelligence in Microsurgical Planning: A Five-Year Leap in Clinical Translation. *Journal of Clinical Medicine*, 14(13), 4574. <https://doi.org/10.3390/jcm14134574>
- Shen, Y., Malek, A. J., Gao, R., & Broyles, J. M. (2025). Artificial intelligence in breast reconstruction. *Artificial Intelligence Surgery*, 5(1), 150-159. <https://doi.org/10.20517/ais.2024.71>
- Wade, R. G., Watford, J., Wormald, J. C. R., Bramhall, R. J., & Figus, A. (2018). Perforator mapping reduces the operative time of DIEP flap breast reconstruction: A systematic review and meta-analysis of preoperative ultrasound, computed tomography and magnetic resonance angiography. *Journal of Plastic, Reconstructive & Aesthetic Surgery*, 71(4), 468-477. <https://doi.org/10.1016/j.bjps.2017.12.012>
- Whiting, P. F., Rutjes, A. W. S., Westwood, M. E., Mallett, S., Deeks, J. J., Reitsma, J. B., Leeflang, M. M. G., Sterne, J. A. C., Bossuyt, P. M. M., & the QUADAS-2 Group*. (2011). QUADAS-2: A Revised Tool for the Quality Assessment of Diagnostic Accuracy Studies. *Annals of Internal Medicine*, 155(8), 529-536. <https://doi.org/10.7326/0003-4819-155-8-201110180-00009>



- Wolff, R. F., Moons, K. G. M., Riley, R. D., Whiting, P. F., Westwood, M., Collins, G. S., Reitsma, J. B., Kleijnen, J., Mallett, S., & for the PROBAST Group†. (2019). PROBAST: A Tool to Assess the Risk of Bias and Applicability of Prediction Model Studies. *Annals of Internal Medicine*, 170(1), 51-58. <https://doi.org/10.7326/M18-1376>
- Xie, Y., Seth, I., Rozen, W. M., & Hunter-Smith, D. J. (2023). Evaluation of the Artificial Intelligence Chatbot on Breast Reconstruction and Its Efficacy in Surgical Research: A Case Study. *Aesthetic Plastic Surgery*, 47(6), 2360-2369. <https://doi.org/10.1007/s00266-023-03443-7>

