

**Aplicación de la inteligencia  
artificial en el diagnóstico y  
tratamiento del hepatocarcinoma**

**Application of artificial  
intelligence in diagnosis and  
treatment of hepatocellular  
carcinoma**

10.20960/revcancer.00113

06/10/2025

**00113 REV**

**Aplicación de la inteligencia artificial en el diagnóstico y tratamiento del hepatocarcinoma**

*Application of artificial intelligence in diagnosis and treatment of hepatocellular carcinoma*

Miguel Jiménez Pérez, Rocío González Grande

UGC de Aparato Digestivo. Unidad de Hepatología-Trasplante Hepático. Instituto de Investigación Biomédica de Málaga (IBIMA). Plataforma BIONAD. Hospital Regional Universitario de Málaga. Málaga

**Correspondencia:** Miguel Jiménez-Pérez. UGC de Aparato Digestivo. Unidad de Hepatología-Trasplante Hepático. Hospital Regional Universitario de Málaga. Avda Carlos Haya. 29010 Málaga  
e-mail: [mjimenezp@uma.es](mailto:mjimenezp@uma.es)

*Contribución de los autores: Miguel Jiménez Pérez y Rocío González Grande han contribuido por igual en este trabajo.*

*Conflictos de intereses: los autores declaran no tener conflicto de interés.*

*Inteligencia artificial: los autores declaran no haber empleado inteligencia artificial (IA) ni ninguna herramienta que use IA para la redacción del artículo.*

## RESUMEN

Aunque la inteligencia artificial (AI, del inglés *artificial intelligence*) comenzó su desarrollo hace ya bastante años no ha sido hasta la última década cuando ha experimentado un espectacular avance en el campo de la Medicina. Su aplicación en Hepatología es de especial relevancia para el estudio del hepatocarcinoma (HCC), debido a sus particulares características radiológicas, que permiten su diagnóstico sin estudios histológicos, aunque la interpretación de imágenes no es fácil debido al hecho de que varían a lo largo del transcurso de la enfermedad, con el pronóstico y la respuesta al tratamiento siendo condicionadas por múltiples factores. Todo ello condiciona una gran cantidad de datos en los que la AI tiene un papel esencial a la hora de analizarlos, ayudando en la toma de decisiones y en salvar las limitaciones de la evaluación humana.

Sin embargo, de ello surge la necesidad de estudios prospectivos bien diseñados que eviten posibles sesgos que puedan afectar a la interpretabilidad de las imágenes, lo que afectaría tanto a la aceptación como a la aplicación de estos modelos. Los profesionales ahora deben entender lo útil de estas técnicas, así como sus fortalezas y debilidades.

**Palabras clave:** Inteligencia artificial. *Machine learning*. Carcinoma hepatocelular. Diagnóstico. Tratamiento. Pronóstico.

## ABSTRACT

Although artificial intelligence (AI) was initially developed many years ago, it has experienced spectacular advances over the last 10 years in the field of Medicine. Its application in Hepatology is especially relevant for the study of hepatocellular carcinoma (HCC), due to its particular radiological characteristics which allow its diagnosis without histological studies, although the interpretation of images is not easy due to the fact that they vary over the course of the disease, with both prognosis and treatment response being conditioned by multiple

factors. All these conditions a vast amount of data in which AI plays a key role in analyzing, helping both decision-making and overcoming the limitations of human evaluation.

However, the need for well-designed prospective studies arises in order to avoid any possible bias that may affect the interpretability of the images, thus impairing both acceptance and application of this models. Professionals now need to understand the usefulness of these techniques, as well as their strengths and limitations.

**Keywords:** Artificial intelligence. Machine learning. Hepatocellular carcinoma. Diagnosis. Treatment. Prognostic.

## INTRODUCCIÓN

En la actual era del *big data*, la necesidad del manejo eficiente de la ingente cantidad de información disponible ha propiciado el desarrollo y la aplicación de la AI y sus técnicas en el escenario de la actual Medicina. Aunque el concepto de AI surgió ya en los años 50 del pasado siglo no ha sido hasta recientemente en la última década cuando ha experimentado su verdadero avance (1).

El término de AI hace referencia a todos a aquellos programas informáticos que tratan de reproducir las funciones cognitivas humanas como el aprendizaje y la resolución de problemas. Dentro de la AI se desarrolló inicialmente el aprendizaje automático (ML, en inglés, *machine learning*) como una rama de la misma que partiendo del análisis de datos trata de crear algoritmos que detectan patrones de comportamiento partir de los cuales permiten establecer modelos predictivos. Métodos de ML tales como *support vector machines* (SVM), *artificial neural networks* (ANNs) o *classification and regression trees* (CART) se han aplicado en múltiples estudios en Medicina. El avance informático experimentado en la última década ha permitido la aparición del aprendizaje profundo (DL, *deep learning*) como un nuevo modelo de ML que ha posibilitado el desarrollo de algoritmos

de redes neuronales multicapa, con técnicas como la red neuronal convolucional (CNN, del inglés *convolutional neural network*), una red neuronal artificial, que ha demostrado una gran utilidad en el análisis de imágenes radiológicas (2,3).

Por otro lado, aunque la aplicación de la AI en diversos campos de la Medicina ha demostrado resultados prometedores debemos ser conscientes de sus limitaciones. El tipo retrospectivo de muchos de estos estudios y el empleo de bases de datos no totalmente adecuadas, con los inherentes sesgos que conllevan pueden condicionar la precisión de la AI. Por ello son necesarios el desarrollo de estudios prospectivos, bien diseñados, multicéntricos, libres de sesgos que puedan condicionar su interpretabilidad y limitar su aceptación y aplicación en la práctica clínica, sin olvidar otros aspectos como el coste efectividad, la necesaria regulación por las autoridades sanitarias y los condicionantes éticos.

En el campo de la Hepatología la AI se ha aplicado para el diagnóstico, tratamiento y predicción del pronóstico de distintas patologías, con especial relevancia en su aplicación en el estudio del hepatocarcinoma (HCC) por tratarse de un tumor muy frecuente, con unas particularidades en su comportamiento radiológico que permite su diagnóstico sin necesidad de estudio histológico, por lo que cobra especial importancia el análisis de las pruebas de imágenes cuya interpretación no siempre es fácil, además de su variabilidad en su evolución clínica, pronóstico y respuesta al tratamiento, que además viene condicionado por múltiples factores. Todo ello determina que se disponga de una gran cantidad de datos en cuya integración y análisis eficiente se han aplicado las técnicas de AI dando lugar al desarrollo de numerosos estudios que nos van ayudar en la toma de decisiones y en salvar las limitaciones de la evaluación humana (3-5). La figura 1 muestra la aplicación de la AI en el enfoque del CHC.

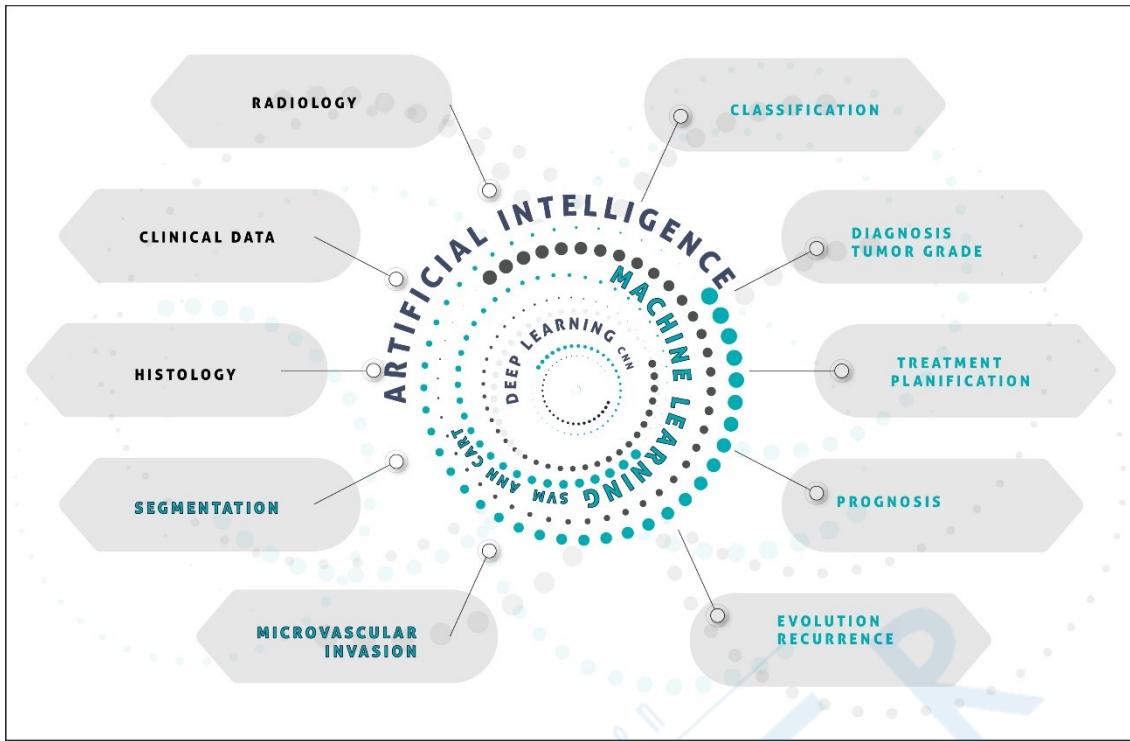


Fig. 1. Aplicación de la AI en el enfoque del CHC. Fuente: elaboración propia.

## **INTELIGENCIA ARTIFICIAL EN EL DIAGNÓSTICO DEL HEPATOCARCINOMA**

En el ámbito de la oncología hepática la aplicación de técnicas de AI en los métodos diagnósticos habituales es prometedora, aumentando el rendimiento y la precisión diagnóstica principalmente de estudios radiológicos, pero también de los histológicos o genéticos.

### **Ecografía abdominal**

El HCC se desarrolla generalmente, aunque no exclusivamente, sobre hígado cirrótico, por ello en los pacientes con cirrosis hepática, siguiendo las recomendaciones de las diferentes guías de práctica clínica, se realizan ecografías abdominales periódicas, considerado el método de elección para el *screening* de lesiones ocupantes de espacio. Por tanto, la ecografía constituye la principal herramienta en la valoración de la enfermedad hepática y en la detección de lesiones

de nueva aparición, pero su interpretación puede ser difícil y presenta variabilidad interobservador.

Respecto a la valoración de la hepatopatía subyacente, Barthi y cols. proponen un modelo de ANN para diferenciar 4 estadios de la enfermedad hepática a través del análisis de datos obtenidos de la imagen ecográfica: hígado normal, hepatopatía crónica, cirrosis y hepatocarcinoma. La precisión del modelo fue del 96,6 % (6).

Liu y cols. exponen un algoritmo de clasificación de imágenes ecográficas que seleccionan la cápsula hepática para establecer la presencia de cirrosis incluso en estadios precoces, cuando los hallazgos habitualmente valorados por el radiólogo como un contorno hepático nodular, aumento de calibre de la porta o esplenomegalia, aún no son evidentes. Utilizando su análisis de la morfología de la cápsula hepática determinan la presencia o ausencia de cirrosis con un área bajo la curva de 0,968 (7).

En cuanto a la caracterización de una lesión hepática a través de la ecografía, el rendimiento humano es limitado. Schamuch y cols. diseñan un sistema de aprendizaje profundo capaz de detectar y clasificar las lesiones hepáticas en benignas y malignas. Tras un entrenamiento supervisado utilizando una base de 367 imágenes junto a anotaciones del radiólogo, el algoritmo resultante consigue la detección y caracterización de las lesiones con un ROC medio de 0,93 y 0,916 respectivamente. Aunque precisa ser validado, el método podría incrementar el rendimiento diagnóstico del ultrasonido (8). Yang y cols., en un estudio multicéntrico empleando un modelo de CNN para diferenciar lesiones hepáticas benignas y malignas, obtuvieron un ROC de 0,92 y una precisión diagnóstica comparable al obtenido con la tomografía axial computarizada (TAC) con contraste y ligeramente inferior al obtenido con la resonancia magnética (9).

La AI también se ha aplicado a la ecografía con contraste mejorando su capacidad para diferenciar lesiones hepáticas benignas de malignas. Guo y cols. demuestran que el aprendizaje profundo aplicado al comportamiento de las lesiones hepáticas en la ecografía

con contraste (C-US, del inglés *contrast ultrasound*) en 3 fases (arterial, portal y tardía) aumentan la precisión, la sensibilidad y la especificidad del estudio (10). En otro estudio multicéntrico reciente un modelo basado en C-US ha demostrado un rendimiento significativamente mejor (precisión de 0,85 a 0,86) que los radiólogos C-US junior (0,59-0,73), y un rendimiento comparable al de los radiólogos C-US senior (0,79-0,85) y radiólogos de resonancia magnética (MR, del inglés *magnetic resonance*) senior (0,82-0,86) para la clasificación múltiple precisa de las lesiones focales hepáticas (11).

### **Tomografía computarizada de abdomen con contraste intravascular (IV)**

Cuando en la ecografía de seguimiento se detecta una lesión hepática *de novo*, se procede a la realización de otras pruebas de imagen, principalmente tomografía computarizada con contraste (CT, del inglés *contrast-enhanced computed tomography*) o MR para una valoración más precisa. El comportamiento radiológico de las lesiones hepáticas en el estudio dinámico con CT o MR es útil para su caracterización. Si una lesión hepática mayor de 1 cm cumple criterios radiológicos, casi patognomónicos de hepatocarcinoma tales como la presencia de hipercaptación en fase arterial y lavado tardío en fase portal en un paciente cirrótico, no son precisos más estudios para su diagnóstico ni confirmación histológica. Sin embargo, en muchas ocasiones los nódulos hepáticos presentan un comportamiento indeterminado en la CT y es precisa la realización de una biopsia de la lesión o un seguimiento estrecho con la necesidad de un elevado número de exploraciones y la posibilidad de no diagnosticar a tiempo una lesión maligna. En este sentido, Mokrane y cols. (12) analizan de forma retrospectiva 178 pacientes con cirrosis hepática y nódulos hepáticos en los que los criterios LIRADS (*Liver Imaging Reporting and Data System*) no fueron capaces de distinguir los neoplásicos de los no neoplásicos, por lo que precisaron biopsia. El

77 % fueron malignos en la biopsia. Utilizando técnicas de aprendizaje profundo para clasificar nódulos en HCC y no HCC consiguen área bajo la curva (AUC) de 0,70 IC 95 %.

Yasaka y cols. (13) realizan un estudio retrospectivo para analizar el rendimiento de una ANN, compuesta por 3 capas, en la clasificación de masas hepáticas mediante CT con contraste en 5 categorías: categoría A, hepatocarcinoma típico; categoría B, tumores malignos diferentes al HCC (colangiocarcinoma, hepatocolangiocarcinoma o metástasis); categoría C, masas indeterminadas, nódulos displásicos o HCC temprano y masas benignas diferentes de quistes o hemangiomas; categoría D, hemangiomas; y categoría E, quistes. Tras un entrenamiento supervisado utilizando más de 55 000 conjuntos de imágenes, obtienen una elevada precisión en la clasificación de las lesiones hepáticas, sobre todo en la diferenciación de las categorías A-B de C-D. Estudios recientes obtienen resultados en la misma línea (14,15).

Cuantificar la carga tumoral puede resultar útil sobre todo en la detección de recidiva de tumores en los CT de seguimiento. Dado que los tumores recidivados pueden ser pequeños y pasar desapercibidos, Vivanti y cols. describen un método de detección automática de recidiva, basándose en la apariencia inicial del tumor, su comportamiento en CT y la cuantificación de la carga tumoral basal y en el seguimiento. El método presentó una elevada tasa de verdaderos positivos en la identificación de recurrencia tumoral con una precisión del 86 % (16).

La segmentación hepática es de gran importancia para la valoración de lesiones hepáticas y la planificación del tratamiento idóneo, pero la segmentación manual está dificultada por la heterogenicidad de las lesiones o los límites difuso de las mismas. Li y cols. proponen un CNN que permite la segmentación de tumores hepáticos a partir de imágenes de CT con una precisión de  $82.67 \pm 1,43 \%$ , superior a otros métodos tradicionales (17), favoreciendo una adecuada planificación terapéutica. Otros estudios empleando modelos de

segmentación semiautomática con imágenes de RMN obtuvieron un rendimiento entre aceptable y bueno (18).

### **Resonancia magnética nuclear de abdomen**

La radiómica por MR se perfila como una prometedora herramienta complementaria para la detección precoz del CHC y la toma de decisiones personalizadas (19).

Hamm y cols. (20) desarrollan y validan un sistema de aprendizaje profundo basado en una CNN que clasifica las lesiones hepáticas en la MR con un 92 % de precisión, un 92 % de sensibilidad y un 98 % de especificidad y un tiempo promedio de ejecución de 5,6 minutos. Otros estudios asocian secuencias adicionales de MR y factores de riesgo y datos clínicos del paciente y aplicando un sistema de clasificación automática catalogan a las lesiones hepáticas en adenomas, quistes, hemangiomas, HCC y metástasis con una sensibilidad y especificidad de 0,8/0,78, 0,93/0,93, 0,84/0,82, 0,73/0,56 y 0,62/0,77, respectivamente (21). Un reciente estudio ha demostrado unos significativos mejores resultados en el diagnóstico diferencial entre HCC y colangiocarcinoma en comparación con los métodos convencionales empleando un modelo de ML con MR (22).

### **Tomografía por emisión de positrones (PET)**

Preis y cosl. evalúan el rendimiento de *Fluorine 18 fluorodeoxyglucose positron emission tomography/computed tomography* (18F-FDG PET/CT) utilizando una red neuronal que analiza la absorción hepática de 18F junto a datos del paciente y de laboratorio, demostrando una elevada sensibilidad y especificidad para detectar malignidad hepática que visualmente no es identificada, constituyendo un complemento al radiólogo en la interpretación del PET (23), aunque su objetivo fue fundamentalmente la valoración de la enfermedad hepática metastásica, donde el 18F-FDG PET/CT tiene mayor aplicabilidad.

## **Histología**

La clasificación histopatológica de una lesión hepática y la diferenciación de la estirpe tumoral es crucial para la planificación del tratamiento y la estimación pronóstica de la enfermedad, pero en ocasiones está limitada hasta para patólogos expertos. Kiani y cols. se centran en la diferenciación histológica entre hepatocarcinoma y colangiocarcinoma y aplican la AI como apoyo a los patólogos. Analizan de forma prospectiva el impacto de dicho asistente en el rendimiento diagnóstico de 11 patólogos sin que ello modificara la precisión media de los mismos (24). Sin embargo, otros autores describen como un modelo de CNN utilizando imágenes previas de histología de HCC fue capaz de realizar el diagnóstico automático de HCC y distinguir el tejido tumoral del sano, identificando además determinados predictores biológicos (25).

## **Biología molecular y biomarcadores**

La AI también se ha aplicado en el análisis de la ingente cantidad de datos genómicos y moleculares disponibles, generando algoritmos enfocados a la mejora de la detección y caracterización de los tumores entre ellos el HCC con resultados prometedores, aunque todavía es necesario el establecimiento de métodos y protocolos estandarizados para la optimización de los resultados (4).

La tabla I recoge una selección de estudios que utilizan técnicas de AI en el diagnóstico del HCC.

## **INTELIGENCIA ARTIFICIAL EN EL TRATAMIENTO DEL HEPATOCARCINOMA**

La variabilidad biológica en el comportamiento del HCC en cada paciente hace que sea difícil el tener un asesoramiento clínico basado en la evidencia científica que sea aplicable a todos los pacientes. El disponer de sistemas de estratificación de riesgo estandarizados y potentes se hacen necesarios para optimizar las estrategias terapéuticas y evaluar sus efectos, y es aquí donde la AI desempeña

un papel importante en el abordaje terapéutico del HCC. La mayoría de los estudios publicados de aplicación de la AI en el tratamiento del HCC van dirigidos al análisis de determinadas características del tumor ya sean radiológicas, histológicas, genéticas y su combinación con datos clínicos para predecir la respuesta a un determinado tratamiento, lo que a su vez permitirá la adecuada selección de pacientes para determinados tratamientos.

### **Estrategias de AI basadas en la radiómica**

En la práctica clínica habitual son las técnicas de imagen mediante C-US, CT y MR en las que se basa el diagnóstico del CHC y la evaluación de los resultados tras la administración de un tratamiento, analizando determinadas características del tumor como su vascularización, comportamiento tras la administración de contraste... (26). Sin embargo, estas características están sujetas a la subjetividad de la interpretación del radiólogo, así como a la ausencia de imágenes dimensionales de alta calidad. En los últimos años ha surgido una tecnología novedosa en el campo de la radiología y el cáncer, la radiómica que, aunque aún no tiene un uso extendido en la práctica clínica, ha despertado gran interés. Esta tecnología permite la extracción de una gran cantidad de datos cuantificables y objetivos contenidos en las imágenes radiológicas y su posterior relación con los procesos biológicos subyacentes permitiendo tras su análisis con *software* de inteligencia artificial la obtención de información diagnóstica, pronóstica y de precisión predictiva (27) .

### **Evaluación de la resección quirúrgica**

La *recurrencia precoz* tumoral tras la resección quirúrgica se asocia a un mal pronóstico. La identificación preoperatoria de pacientes con alto riesgo de recurrencia se hace fundamental para evitar tratamientos innecesarios. En este sentido se han desarrollado modelos que analizando determinadas características del tumor

ayudan a la predicción preoperatoria del riesgo de recurrencia o a evaluar la supervivencia tras la resección.

La *microinvasión vascular* (MIV) se ha establecido como un factor predictivo independiente de recurrencia asociado a pobres resultados tras la resección tumoral (28). El poder disponer de información preoperatoria de MIV sería de gran ayuda, sin embargo las técnicas radiológicas habitualmente empleadas en la práctica clínica no permiten hacer un diagnóstico directo y adecuado.

Diversos estudios han conseguido elaborar firmas radiómicas que permiten predecir el estatus preoperatorio de MIV empleando como base el CT con contraste (29-31) y la RMN (32). Sin embargo, estas técnicas tienen la limitación de la exposición radiológica, lo laborioso de su realización y el coste. Ya hay estudios (33,34) que mediante algoritmos radiómicos basados sobre imágenes de ultrasonidos han permitido elaborar firmas radiómicas con potencial valor en la predicción del MIV con resultados prometedores.

Ji y cols. (35) han creado modelos predictivos sobre recurrencia tras la resección quirúrgica aplicando técnicas radiómicas mediante análisis de imágenes de CT, con un *c-index* de 0,633-0,699, permitiendo al integrarlos con datos clínicos el establecer una estratificación de riesgo individualizado que facilita el manejo personalizado del HCC.

La *supervivencia* tras la resección quirúrgica también ha sido evaluada en varios estudios empleando técnicas de ML (36-38). Saillard y cols. (39), empleando modelos avanzados de *deep learning* (DL) sobre la base de imágenes histológicas del tumor digitalizadas, han elaborado un modelo predictivo de supervivencia tras la resección alcanzando un *c-index* de predicción de supervivencia del 0,78. También recientemente Schoemberg y cols. (40), en un estudio prospectivo sobre 180 pacientes han elaborado un modelo predictivo basado en el análisis de 26 variables clínicas preoperatorias rutinarias obteniendo un valor predictivo de 0,78

## **Evaluación de la TACE (*transcatheter arterial chemoembolization*)**

La TACE (*transcatheter arterial chemoembolization*) es el tratamiento de elección para el HCC en estadio intermedio B, de la clasificación BCLC (*Barcelona Clinical Liver Cancer*) (41). La selección adecuada de los pacientes que se van a beneficiar de este tratamiento es fundamental para evitar exploraciones innecesarias a veces con posibles efectos indeseables para el paciente y el ahorro en costes para el sistema sanitario. En este sentido se han desarrollado estudios que basándose en técnicas de AI tratan de predecir la respuesta al tratamiento con TACE y ayudar a una adecuada selección del paciente. La mayoría de estos estudios se han basado en el análisis de técnicas de imágenes, pero también algunos otros lo han hecho sobre el estudio de firmas genómicas. Morshid y cols. (42) elaboraron un algoritmo mediante ML completamente automatizado empleando la combinación de características cuantitativas de imágenes de CT y datos clínicos de los pacientes pretratamiento para predecir la respuesta a la TACE, obteniendo una precisión predictiva del 74,2 %. Peng y cols. (43) han validado un modelo de DL para predecir la respuesta a la TACE empleando imágenes de CT de un total de 789 pacientes de tres hospitales distintos obteniendo una precisión del 84 % y AUC del 0,97 para predecir la respuesta completa. Liu y cols. (44) han construido y validado un modelo de DL pero basado en ultrasonidos con contraste altamente reproducible y con AUC del 0,93 (95 % CI, 0,80-0,98) en la predicción de la respuesta a la TACE.

También se han realizado estudios aplicando técnicas de ML combinando imágenes de MR y datos clínicos para predecir la respuesta a la TACE, en este sentido Abajian y cols. (45) estudiaron 36 pacientes sometidos a MR pre-TACE, elaborando un modelo predictivo de respuesta con una AUC: 78 %, sensibilidad 62,5 % y especificidad: 82 %.

La evaluación de la eficacia de la TACE también ha sido evaluada mediante el análisis de la supervivencia de los pacientes tras su aplicación. Mähringer-Kunz y cols. (46) han desarrollado un modelo de predicción de supervivencia tras la TACE mediante la construcción ANN empleando todos los parámetros de los principales *scores* de predicción convencionales (ART [47], ABCR [48], y SNACOR [49]) y prediciendo la supervivencia a un año con un AUC de 0,77, sensibilidad del 78 % y especificidad del 81 %, resultados superiores cuando se les comparó con los de los scores convencionales mencionados.

Aunque la mayoría de los estudios que evalúan la TACE aplicando técnicas de AI lo han hecho dentro del ámbito de la radiómica, algún estudio también ha evaluado la predicción de la respuesta a la TACE sobre el análisis genético. Zie y cols. (50) estudiaron mutaciones genéticas empleando técnicas de SVM que pudieran predecir la respuesta del tumor a la TACE, aunque se trata de un estudio retrospectivo con un bajo número de casos.

### **Evaluación de la ablación con radiofrecuencia**

Liang y cols. (51) elaboraron un modelo predictivo de recurrencia del HCC basado en *support vector machine* (SVM) estudiando 83 pacientes con HCC que fueron sometidos a RFA (del inglés, *radiofrequency ablation*) obteniendo un AUC del 67 %, con una sensibilidad del 86 % y especificidad del 82 %, permitiendo identificar pacientes con alto riesgo de recurrencia.

La tabla II recoge una selección de estudios que aplican la AI para la evaluación del tratamiento del HCC.

### **PREDICCIÓN DE LA SUPERVIVENCIA GLOBAL DEL HEPATOCARCINOMA**

Las técnicas de AI también han demostrado que son capaces de predecir con fiabilidad la probabilidad de supervivencia de los pacientes con HCC en todos los estadios. Así en un estudio reciente

Steven y cols. (52) encontraron que para pacientes en estadio temprano (estadios 1-2), los modelos alcanzaron valores de precisión de hasta el 91 % para la predicción de supervivencia a los 6 meses y para los de estadio avanzado (estadio 4) del hasta el 92 % a los 3 años.

## **DIRECTRICES FUTURAS**

Se precisan estudios más amplios que comparan el rendimiento de los profesionales médicos con el apoyo de AI frente a otros profesionales sin dicho apoyo para demostrar su beneficio como ayuda en Medicina. En particular, para evaluar las lesiones hepáticas y estudiar el HCC, estos ensayos deben centrarse en aspectos relacionados con el tratamiento y el pronóstico, como la caracterización de las lesiones hepáticas catalogadas como indeterminadas, la presencia de invasión vascular y la respuesta a la terapia percutánea. Otro aspecto importante a considerar es el empleo de la AI en el análisis del comportamiento del HCC en cirróticos y no cirróticos, así como en la diferenciación de lesiones primarias de las metastásicas y especialmente en el diagnóstico diferencial con el colangiocarcinoma. Al mismo tiempo es necesario comenzar a capacitar a los profesionales de la salud para que estén preparados para la futura incorporación de la AI en la práctica clínica en el campo del cáncer de hígado.

## **CONCLUSIÓN**

Sin lugar a duda la irrupción de la tecnología de AI en la Medicina ha sido uno de los avances más relevantes en los últimos años y que experimentará un creciente y progresivo auge, por su utilidad en el procesamiento y análisis de la ingente cantidad de datos de la que se dispone actualmente. Sin embargo, debemos ser conscientes de que todavía quedan condicionantes que pueden limitar su aceptación y aplicabilidad en la práctica clínica. Los profesionales deberemos aprender la verdadera utilidad de la AI y la necesidad de su

coexistencia con la insustituible evaluación humana, y asumir que viene para apoyar a la inteligencia humana y nunca para sustituirla.

## BIBLIOGRÍA

1. Turing AM. I. Computing machinery and intelligence. *Mind* 1950; LIX: 433-60. DOI: 10.1093/mind/LIX.236.433
2. Yang YJ, Bang CS. Application of artificial intelligence in gastroenterology. *World J Gastroenterol* 2019;25:1666-83. DOI: 10.3748/wjg.v25.i14.1666
3. Le Berre C, Sandborn WJ, Aridhi S, Devignes M-D, Fournier L, Smaïl-Tabbone M, et al. Application of Artificial Intelligence to Gastroenterology and Hepatology. *Gastroenterology* 2020;158:76-94.e2. DOI: 10.1053/j.gastro.2019.08.058
4. Calderaro J, Seraphin TP, Luedde T, Simon TG. Artificial intelligence for the prevention and clinical management of hepatocellular carcinoma. *J Hepatol* 2022;76:1348-61. DOI: 10.1016/j.jhep.2022.01.014
5. Salehi MA, Harandi H, Mohammadi S, Shahrabi Farahani M, Shojaei S, Saleh RR. Diagnostic Performance of Artificial Intelligence in Detection of Hepatocellular Carcinoma: A Meta-analysis. *J Imaging Inform Med* 2024;37:1297-311. DOI: 10.1007/s10278-024-01058-1
6. Bharti P, Mittal D, Ananthasivan R. Preliminary Study of Chronic Liver Classification on Ultrasound Images Using an Ensemble Model. *Ultrason Imaging* 2018;40:357-79. DOI: 10.1177/0161734618787447
7. Liu X, Song J, Wang S, Zhao J, Chen Y. Learning to Diagnose Cirrhosis with Liver Capsule Guided Ultrasound Image Classification. *Sensors* 2017;17:149. DOI: 10.3390/s17010149
8. Schmauch B, Herent P, Jehanno P, Dehaene O, Saillard C, Aubé C, et al. Diagnosis of focal liver lesions from ultrasound using deep learning. *Diagnostic and Interventional Imaging* 2019;100:227-33. DOI: 10.1016/j.diii.2019.02.009

9. Yang Q, Wei J, Hao X, Kong D, Yu X, Jiang T, et al. Improving B-mode ultrasound diagnostic performance for focal liver lesions using deep learning: A multicentre study. *EBioMedicine* 2020;56:102777. DOI: 10.1016/j.ebiom.2020.102777
10. Guo L-H, Wang D, Qian Y-Y, Zheng X, Zhao C-K, Li X-L, et al. A two-stage multi-view learning framework based computer-aided diagnosis of liver tumors with contrast enhanced ultrasound images. *CH* 2018;69:343-54. DOI: 10.3233/CH-170275
11. Ding W, Meng Y, Ma J, Pang C, Wu J, Tian J, et al. Contrast-enhanced ultrasound-based AI model for multi-classification of focal liver lesions. *J Hepatol* 2025;S0168-8278(25)00018-2. DOI: 10.1016/j.jhep.2025.01.011
12. Mokrane F-Z, Lu L, Vavasseur A, Otal P, Peron J-M, Luk L, et al. Radiomics machine-learning signature for diagnosis of hepatocellular carcinoma in cirrhotic patients with indeterminate liver nodules. *Eur Radiol* 2020;30:558-70. DOI: 10.1007/s00330-019-06347-w
13. Yasaka K, Akai H, Abe O, Kiryu S. Deep Learning with Convolutional Neural Network for Differentiation of Liver Masses at Dynamic Contrast-enhanced CT: A Preliminary Study. *Radiology* 2018;286:887-96. DOI: 10.1148/radiol.2017170706
14. Inmutto N, Pojchamarnwiputh S, Na Chiangmai W. Multiphase Computed Tomography Scan Findings for Artificial Intelligence Training in the Differentiation of Hepatocellular Carcinoma and Intrahepatic Cholangiocarcinoma Based on Interobserver Agreement of Expert Abdominal Radiologists. *Diagnostics (Basel)* 2025;15:821. DOI: 10.3390/diagnostics15070821
15. Hu R, Li H, Horng H, Thomasian NM, Jiao Z, Zhu C, et al. Automated machine learning for differentiation of hepatocellular carcinoma from intrahepatic cholangiocarcinoma on multiphasic MRI. *Sci Rep* 2022;12:7924. DOI: 10.1038/s41598-022-11997-w

16. Vivanti R, Szeskin A, Lev-Cohain N, Sosna J, Joskowicz L. Automatic detection of new tumors and tumor burden evaluation in longitudinal liver CT scan studies. *Int J CARS* 2017;12:1945-57. DOI: 10.1007/s11548-017-1660-z
17. Li W, Jia F, Hu Q. Automatic Segmentation of Liver Tumor in CT Images with Deep Convolutional Neural Networks. *JCC* 2015;03:146-51. DOI: 10.4236/jcc.2015.311023
18. Said D, Carbonell G, Stocker D, Hectors S, Vietti-Violi N, Bane O, et al. Semiautomated segmentation of hepatocellular carcinoma tumors with MRI using convolutional neural networks. *Eur Radiol* 2023;33:6020-32. DOI: 10.1007/s00330-023-09613-0
19. Xie X-Y, Chen R. Research progress of MRI-based radiomics in hepatocellular carcinoma. *Front Oncol* 2025;15:1420599. DOI: 10.3389/fonc.2025.1420599
20. Hamm CA, Wang CJ, Savic LJ, Ferrante M, Schobert I, Schlachter T, et al. Deep learning for liver tumor diagnosis part I: development of a convolutional neural network classifier for multi-phasic MRI. *Eur Radiol* 2019;29:3338-47. DOI: 10.1007/s00330-019-06205-9
21. Jansen MJA, Kuijf HJ, Veldhuis WB, Wessels FJ, Viergever MA, Pluim JPW. Automatic classification of focal liver lesions based on MRI and risk factors. *PLoS ONE* 2019;14:e0217053. DOI: 10.1371/journal.pone.0217053
22. Deng X, Liao Z. A machine-learning model based on dynamic contrast-enhanced MRI for preoperative differentiation between hepatocellular carcinoma and combined hepatocellular-cholangiocarcinoma. *Clin Radiol* 2024;79:e817-e825. DOI: 10.1016/j.crad.2024.02.001
23. Preis O, Blake MA, Scott JA. Neural Network Evaluation of PET Scans of the Liver: A Potentially Useful Adjunct in Clinical Interpretation. *Radiology* 2011;258:714-21. DOI: 10.1148/radiol.10100547

24. Kiani A, Uyumazturk B, Rajpurkar P, Wang A, Gao R, Jones E, et al. Impact of a deep learning assistant on the histopathologic classification of liver cancer. *npj Digit Med* 2020;3:23. DOI: 10.1038/s41746-020-0232-8
25. Liao H, Xiong T, Peng J, Xu L, Liao M, Zhang Z, et al. Classification and Prognosis Prediction from Histopathological Images of Hepatocellular Carcinoma by a Fully Automated Pipeline Based on Machine Learning. *Ann Surg Oncol* (e-pub ahead of print 8 January 2020; DOI: 10.1245/s10434-019-08190-1
26. Singal AG, Llovet JM, Yarchoan M, Mehta N, Heimbach JK, Dawson LA, et al. AASLD Practice Guidance on prevention, diagnosis, and treatment of hepatocellular carcinoma. *Hepatology* 2023;78:1922-65. DOI: 10.1097/HEP.000000000000466
27. Lambin P, Leijenaar RTH, Deist TM, Peerlings J, de Jong EEC, van Timmeren J, et al. Radiomics: the bridge between medical imaging and personalized medicine. *Nature Reviews Clinical Oncology* 2017;14:749-62. DOI: 10.1038/nrclinonc.2017.141
28. Erstad DJ, Tanabe KK. Prognostic and Therapeutic Implications of Microvascular Invasion in Hepatocellular Carcinoma. *Ann Surg Oncol* 2019;26:1474-93. DOI: 10.1245/s10434-019-07227-9
29. Ma X, Wei J, Gu D, Zhu Y, Feng B, Liang M, et al. Preoperative radiomics nomogram for microvascular invasion prediction in hepatocellular carcinoma using contrast-enhanced CT. *Eur Radiol* 2019;29:3595-605. DOI: 10.1007/s00330-018-5985-y
30. Xu X, Zhang H-L, Liu Q-P, Sun S-W, Zhang J, Zhu F-P, et al. Radiomic analysis of contrast-enhanced CT predicts microvascular invasion and outcome in hepatocellular

- carcinoma. *J Hepat* 2019;70:1133-44. DOI: 10.1016/j.jhep.2019.02.023
31. He X, Xu Y, Zhou C, Song R, Liu Y, Zhang H, et al. Prediction of microvascular invasion and pathological differentiation of hepatocellular carcinoma based on a deep learning model. *Eur J Radiol* 2024;172:111348. DOI: 10.1016/j.ejrad.2024.111348
32. Zhang C, Ma L, Zhang X-L, Lei C, Yuan S-S, Li J-P, et al. Magnetic Resonance Deep Learning Radiomic Model Based on Distinct Metastatic Vascular Patterns for Evaluating Recurrence-Free Survival in Hepatocellular Carcinoma. *J Magn Reson Imaging* 2024;60:231-42. DOI: 10.1002/jmri.29064
33. Dong Y, Zhou L, Xia W, Zhao X-Y, Zhang Q, Jian J-M, et al. Preoperative Prediction of Microvascular Invasion in Hepatocellular Carcinoma: Initial Application of a Radiomic Algorithm Based on Grayscale Ultrasound Images. *Front Oncol* 2020;10:353. DOI: 10.3389/fonc.2020.00353
34. Zhang Y, Wei Q, Huang Y, Yao Z, Yan C, Zou X, et al. Deep Learning of Liver Contrast-Enhanced Ultrasound to Predict Microvascular Invasion and Prognosis in Hepatocellular Carcinoma. *Front Oncol* 2022;12:878061. DOI: 10.3389/fonc.2022.878061
35. Ji G-W, Zhu F-P, Xu Q, Wang K, Wu M-Y, Tang W-W, et al. Machine-learning analysis of contrast-enhanced CT radiomics predicts recurrence of hepatocellular carcinoma after resection: A multi-institutional study. *EBioMedicine* 2019;50:156-65. DOI: 10.1016/j.ebiom.2019.10.057
36. Huang C, Hu P, Tian Y, Wang Y, Gao Y, Qi Q, et al. Whole-Liver Based Deep Learning for Preoperatively Predicting Overall Survival in Patients with Hepatocellular Carcinoma. *Stud Health Technol Inform* 2024;310:926-30. DOI: 10.3233/SHTI231100
37. Chiu H-C, Ho T-W, Lee K-T, Chen H-Y, Ho W-H. Mortality predicted accuracy for hepatocellular carcinoma patients with

- hepatic resection using artificial neural network. *ScientificWorldJournal* 2013;2013:201976. DOI: 10.1155/2013/201976
38. Shi H-Y, Lee K-T, Lee H-H, Ho W-H, Sun D-P, Wang J-J, et al. Comparison of Artificial Neural Network and Logistic Regression Models for Predicting In-Hospital Mortality after Primary Liver Cancer Surgery. *PLOS ONE* 2012;7:e35781. DOI: 10.1371/journal.pone.0035781
39. Saillard C, Schmauch B, Laifa O, Moarii M, Toldo S, Zaslavskiy M, et al. Predicting survival after hepatocellular carcinoma resection using deep-learning on histological slides. *Hepatology* 2020;72(6):2000-13. DOI: 10.1002/hep.31207.
40. Schoenberg MB, Bucher JN, Koch D, Börner N, Hesse S, De Toni EN, et al. A novel machine learning algorithm to predict disease free survival after resection of hepatocellular carcinoma. *Ann Transl Med* 2020;8(7):434. DOI: 10.21037/atm.2020.04.16
41. Reig M, Forner A, Rimola J, Ferrer-Fàbrega J, Burrel M, Garcia-Criado Á, et al. BCLC strategy for prognosis prediction and treatment recommendation: The 2022 update. *J Hepatol* 2022;76(3):681-93. DOI: 10.1016/j.jhep.2021.11.018
42. Morshid A, Elsayes KM, Khalaf AM, Elmohr MM, Yu J, Kaseb AO, et al. A machine learning model to predict hepatocellular carcinoma response to transcatheter arterial chemoembolization. *Radiol Artif Intell* 2019;1(5):e180021. DOI: 10.1148/ryai.2019180021
43. Peng J, Kang S, Ning Z, Deng H, Shen J, Xu Y, et al. Residual convolutional neural network for predicting response of transarterial chemoembolization in hepatocellular carcinoma from CT imaging. *Eur Radiol* 2020;30:413-24. DOI: 10.1007/s00330-019-06318-1
44. Liu D, Liu F, Xie X, Su L, Liu M, Xie X, et al. Accurate prediction of responses to transarterial chemoembolization for

- patients with hepatocellular carcinoma by using artificial intelligence in contrast-enhanced ultrasound. *Eur Radiol* 2020;30:2365-76. [DOI: 10.1007/s00330-019-06553-6]
45. Abajian A, Murali N, Savic LJ, Laage-Gaupp FM, Nezami N, Duncan JS, et al. Predicting Treatment Response to Image-Guided Therapies Using Machine Learning: An Example for Trans-Arterial Treatment of Hepatocellular Carcinoma. *J Vis Exp* 2018;(140):58382. DOI: 10.3791/58382
46. Mähringer-Kunz A, Wagner F, Hahn F, Weinmann A, Brodehl S, Schotten S, et al. Predicting survival after transarterial chemoembolization for hepatocellular carcinoma using a neural network: A Pilot Study. *Liver International* 2020;40:694-703. DOI: 10.1111/liv.14380
47. Sieghart W, Hucke F, Pinter M, Graziadei I, Vogel W, Müller C, et al. The ART of decision making: retreatment with transarterial chemoembolization in patients with hepatocellular carcinoma. *Hepatology* 2013;57:2261-73. DOI: 10.1002/hep.26256
48. Adhoute X, Penaranda G, Naude S, Raoul JL, Perrier H, Bayle O, et al. Retreatment with TACE: the ABCR SCORE, an aid to the decision-making process. *J Hepatol* 2015;62:855-62. DOI: 10.1016/j.jhep.2014.11.014
49. Kim BK, Shim JH, Kim SU, Park JY, Kim DY, Ahn SH, et al. Risk prediction for patients with hepatocellular carcinoma undergoing chemoembolization: development of a prediction model. *Liver Int* 2016;36:92-9. DOI: 10.1111/liv.12865
50. Ziv E, Yarmohammadi H, Boas FE, Petre EN, Brown KT, Solomon SB, et al. Gene Signature Associated with Upregulation of the Wnt/β-Catenin Signaling Pathway Predicts Tumor Response to Transarterial Embolization. *J Vasc Interv Radiol* 2017;28:349-55.e1. DOI: 10.1016/j.jvir.2016.11.004
51. Liang J-D, Ping X-O, Tseng Y-J, Huang G-T, Lai F, Yang P-M. Recurrence predictive models for patients with hepatocellular

- carcinoma after radiofrequency ablation using support vector machines with feature selection methods. *Comput Methods Programs Biomed* 2014;117:425-34. DOI: 10.1016/j.cmpb.2014.09.001
52. Seven İ, Bayram D, Arslan H, Köş FT, Gümüşlü K, Aktürk Esen S, et al. Predicting hepatocellular carcinoma survival with artificial intelligence. *Sci Rep* 2025;15:6226. DOI: 10.1038/s41598-025-90884-6

revisões en  
CANCER

Tabla II. Estudios que aplican la inteligencia artificial para el tratamiento del HCC							Universidad/Departamento		
Autor		Título	n	Tipo de estudio	Objetivo del estudio	Herramienta AI	Resultados		
Autor		Título	n	Tipo de estudio	Objetivo del estudio	Herramienta AI	Técnica diagnóstica estudiada	Herramienta de IA empleada	Universidad/Departamento
Dong et al. (33), 2020		Prediction of microvascular invasion in hepatocellular carcinoma using an ensemble learning radiomic algorithm base on grayscale	322	Retrospectivo	Prediction of VMI	Radiomics	AUC 0.73, Seh 0.919, Spe 0.359		Department of Ultrasound, Zhongshan Hospital, Fudan University, Shanghai, China
Bharti et al. (6), 2018		Preliminary Study of Chronic Liver Disease and Hepatocellular Carcinoma on Ultrasound Images Using an Ensemble Learning Radiomic Algorithm	100	Retrospectivo	Classification of liver disease in four stages; normal liver, chronic liver disease, cirrhosis and HCC	Ultrasound		CNN	Thapar Institute of Engineering & Technology, Patiala, India
Yang et al. (9), 2019		Improving B-mode ultrasound diagnostic performance for focal liver lesions using deep learning	100	Retrospectivo	Identification of focal liver lesions	Ultrasound		CNN	Department of Interventional Ultrasound, Chinese PLA General Hospital, 28 Fuxing
Zhang et al. (34), 2020		Deep learning to differentiate liver lesions using a multi-view learning framework	36	Retrospectivo	Prediction of VMI	DL	AUC 0.86, Seh 71.4%, Spe 81.6%		Department of Ultrasound, Sun Yat-Sen University Cancer Center, State Key Laboratory of Oncology in South China, Collaborative Innovation Center for Cancer Medicine, Guangzhou, China
Schamuch et al. (8), 2019		Diagnosis of focal liver lesions from ultrasound using deep learning and prognosis in hepatocellular carcinoma	0	Retrospectivo	Classify liver lesions as benign or malignant	Ultrasound		DL	Department of Radiology, Paris, France
Guo et al. (10), 2018		A two-stage multi-view learning framework-based computer-aided diagnosis of liver tumor with contrast-enhanced ultrasound	147	Retrospectivo	Characterize liver lesions and identify data of malignancy	C-US		ML	University School of Medicine, Shanghai, China
Ma et al. (29), 2019		Preoperative radiomics program for hepatocellular carcinoma using contrast-enhanced ultrasound images	147	Retrospectivo	Prediction of VMI using C-CT	Radiomics	AUC 0.73		Department of Diagnostic Radiology, National Cancer Center/Cancer Hospital, Chinese Academy of Medical Sciences and Peking Union Medical College
Mokrane et al. (12), 2020		Radiomic machine learning signature for diagnosis of hepatocellular carcinoma in cirrhotic patients with indeterminate liver nodules using contrast-enhanced CT	147	Retrospectivo	Identify malignancy in hepatic space-occupying lesions catalogued as indeterminate	CT			Department of Radiology, New York Presbyterian Hospital, Columbia University Vagelos College of Physicians and Surgeons, New York City, NY, USA
Yasaka et al. (31), 2020		Deep Learning with Convolutional Neural Network for Differentiation of Liver Masses based on microvascular invasion	40	Retrospectivo	Differentiation of liver lesions	CT		CNN	Department of Radiology, The University of Texas MD Anderson Cancer Center, Houston, TX, USA
Han et al. (31), 2018		Network-based differentiation of liver masses using dynamic contrast-enhanced CT: A preliminary study	40	Retrospectivo	Prediction of VMI using CT	DL		AUC 0.941	Department of Radiology, The Second Affiliated Hospital of Chongqing Medical University, Chongqing, PR China
Immutto et al. (14), 2025		Computer tomography scan findings for artificial intelligence training in the differentiation of hepatocellular carcinoma and prehepatocellular cholangiocarcinoma	100	Retrospectivo	Differentiation hepatocellular carcinoma/intrahepatic cholangiocarcinoma	CT		ML	Department of Radiology, Faculty of Medicine, Chiang Mai University, Chiang Mai 50200, Thailand
Seven et al. (53), 2025		and prehepatocellular cholangiocarcinoma Based on interobserver agreement of expert abdominal radiologists	100	Retrospectivo	Prediction survival	ML	Acc: 92%/87.5%		Department of Internal Medicine, Ankara Bilkent City Hospital, Ankara, Turkey
Said et al. (18), 2023		Semiautomated segmentation of hepatocellular carcinoma tumors with MRI using a Convolutional Neural Networks	100	Retrospectivo	Liver tumor segmentation	MRI		CNN	BioMedical Engineering and Imaging Institute, Icahn School of Medicine at Mount Sinai, New York, NY, USA
Morshid et al. (48), 2019		A machine learning model to predict response to TACE using CT	105	Retrospectivo	Prediction of response to TACE using CT	ML	Acc: 74%		Departments of Imaging Physics, Diagnostic Radiology, Gastrointestinal Oncology and Interventional Radiology, The University of Texas MD Anderson Cancer Center, Houston, TX, USA
Hamm et al. (20), 2019		Deep learning for liver tumor diagnosis part I: development of convolutional neural network classifier for multi-phasic MRI chemoembolization	100	Retrospectivo	Classification of liver lesions	MRI		DL	Department of Radiology and Biomedical Imaging, Yale School of Medicine, USA
Hu et al. (15), 2020		Automated machine learning for differentiation of hepatocellular carcinoma	100	Retrospectivo	Differentiation liver lesions	MRI			Department of Radiology, Xiangya Hospital, Changsha, China
Liu et al. (37), 2020		Differentiation of hepatocellular carcinoma from hepatocellular cholangiocarcinoma on multiphasic MRI	100	Retrospectivo	Prediction of response to TACE using C-US	DL		AUC: 0.93	Department of Medical Ultrasound, Institute of Diagnostic and Interventional Ultrasound, First Affiliated Hospital of Sun Yat-sen University, China
Deng et al. (22), 2024		A machine learning model based on dynamic contrast-enhanced MRI for preoperative differentiation between hepatocellular carcinoma and combined hepatocellular-cholangiocarcinoma	100	Retrospectivo	Differentiation liver lesions	MRI		CNN	Medical Imaging Center, Ganzhou People's Hospital, 16th Meiguan Avenue, Ganzhou 341000, China; Ganzhou Institute of Medical Imaging, Ganzhou.
Ding et al. (11), 2025		Contrast-enhanced ultrasound-based AI model for multi-classification of focal liver lesions	100	Retrospectivo	Identify focal liver lesions	C-US		ML	Department of Interventional Ultrasound, Chinese PLA General Hospital, Beijing
Peng et al. (44), 2020		Residual convolutional neural network learning to differentiate HCC from cholangiocarcinoma	789	Retrospectivo	Prediction of response to TACE using C-US	CNN	AUC: 0.97 Acc: 84.3%	Histology	Hepatology Unit and Department of Infectious Diseases, Nanfang Hospital, Southern Medical University, Guangzhou, China
Mani et al. (24), 2020		Impact of a deep learning assistant on the histopathological classification of liver cancer after transarterial chemoembolization in hepatocellular carcinoma	100	Retrospectivo	Differentiate HCC from cholangiocarcinoma	Histology		DL	Department of Computer Science, Stanford University, Stanford, CA, USA
Liao et al. (25), 2020		Deep learning-based classification and mutation prediction from histopathological images of hepatocellular carcinoma	100	Retrospectivo	Automated identification of liver tumor tissue, differentiating it from healthy tissue	Histology		DL	Department of Liver Surgery & Liver Transplantation, State Key Laboratory of Biotherapy and Cancer Center, West China Hospital, Sichuan University, Chengdu, China
Abajian et al. (46), 2018		Predicting Treatment Response to Intra-arterial Therapies for Hepatocellular Carcinoma with the Use of Supervised Machine Learning-An Artificial Intelligence Concept	36	Retrospectivo	Prediction of response to TACE using MRI	ML	Acc: 78%, Seh 62%, Spe 82%		Yale School of Medicine, USA
Mähringer-Kunz et al. (47), 2020		Predicting survival after transarterial chemoembolization for hepatocellular carcinoma using a neural network: A Pilot Study	282	Retrospectivo	Prediction of survival after TACE	CNN	Acc: 0.77, Sen: 78%, Spe: 81%		Department of Diagnostic and Interventional Radiology, University Medical Center of the Johannes Gutenberg-University Mainz, Mainz, Germany

C-US: contrast-enhanced ultrasound; CT: computerized tomography; MRI: magnetic resonance imaging.

VMI: vascular microinvasion; C-US: contrast-enhanced ultrasound; AUC: area under the curve; Acc: accuracy; Sen: sensitivity; Spe: specificity; C-CT: contrast-enhanced CT; C-MRI: contrast-enhanced MRI; TACE: transcatheter arterial chemoembolization.

