

A Scientometric Study of Machine Learning and Deep Learning Methods for Non-Alcoholic Fatty Liver Disease Detection in Medical Imaging

A'adel Sayyahi (MSc student)¹, Seyed Enayatallah Alavi (PhD)^{1*}, Morteza Jaderian (PhD)¹

1. Department of Computer Engineering, Faculty of Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran.

ABSTRACT

Article Type:

Research Paper

Background and aim: This study aims to map the landscape of research related to the detection of non-alcoholic fatty liver disease (NAFLD) using various medical imaging techniques, including ultrasound, MRI, and CT scan, through machine learning and deep learning.

Materials and methods: The scientometric analysis for scientific publications indexed in databases like WoSCC, IEEE Xplore, Scopus and PubMed was done in this descriptive study. The combination of keywords was utilized to identify articles on machine learning, deep learning, and NAFLD detection in medical imaging. The focus in this analysis was on identifying publication trends, geographic distribution, and major sources of research.

Findings: The findings indicated a remarkable increase in the use of machine learning and deep learning techniques for NAFLD detection, especially in the last decade. The United States, China, and India emerged as the biggest contributors in this field. Another interesting finding is related to the importance of international collaboration for the advancement of this field. The collaboration between top universities and international research groups played a very important role in the advancement of research in this field.

Conclusion: According to this scientometric analysis, artificial intelligence is revolutionizing NAFLD diagnosis. Although recent research has reached a noteworthy diagnostic accuracy, especially regarding deep learning, the real-world clinical impact is limited by factors beyond just numerical performance. Research is now shifting focus from mere accuracy to developing interpretable, trustworthy, and clinically applicable models. These results indicate that future AI-driven diagnosis of NAFLD must align technological innovation with practical clinical needs to achieve faster and fairer diagnoses.

Received:

6 Nov. 2025

Revised:

12 Mar. 2026

Accepted:

30 Mar. 2026

Pub. Online:

15 Apr. 2026

Keywords: Machine Learning (ML), Deep Learning (DL), Non-Alcoholic Fatty Liver Disease (NAFLD), Medical imaging

Cite this article: Sayyahi A, Alavi SE, Jaderian M. A Scientometric Study of Machine Learning and Deep Learning Methods for Non-Alcoholic Fatty Liver Disease Detection in Medical Imaging. *Caspian Journal of Scientometrics*. 2026; 13(1): 12-25.



© The Author(s).

Publisher: Babol University of Medical Sciences

*Corresponding Author: Seyed Enayatallah Alavi

Address: Department of Computer Engineering, Faculty of Engineering, Shahid Chamran University of Ahvaz, Golestan Blv., Ahvaz, Iran.

E-mail: se.alavi@scu.ac.ir

مطالعه علم سنجی روش های یادگیری ماشین و یادگیری عمیق برای تشخیص بیماری کبد چرب غیرالکلی در تصویربرداری پزشکی

عادل سیاحی (MSc student)¹، سید عنایت الله علوی (PhD)^{2*}، مرتضی جادریان (PhD)³

۱. گروه مهندسی کامپیوتر، دانشکده مهندسی، دانشگاه شهید چمران اهواز، اهواز، ایران.

چکیده

سابقه و هدف: این پژوهش با هدف ترسیم چشم انداز تحقیقات مرتبط با تشخیص کبد چرب غیرالکلی (NAFLD) با استفاده از روش های تصویربرداری پزشکی مانند سونوگرافی، تصویربرداری تشدید مغناطیسی (MRI) و توموگرافی کامپیوتری (CT) از طریق رویکردهای یادگیری ماشینی و یادگیری عمیق انجام شده است. مواد و روش ها: در این مطالعه توصیفی، تحلیل علم سنجی بر روی انتشارات نمایه شده در پایگاه های اطلاعاتی Web of Science، IEEE Xplore، Scopus و PubMed انجام گرفت. از ترکیب کلمات کلیدی مرتبط با یادگیری ماشینی، یادگیری عمیق و تشخیص کبد چرب غیرالکلی در تصویربرداری پزشکی برای شناسایی مقالات استفاده شد. تمرکز این تحلیل بر شناسایی روندهای انتشار، توزیع جغرافیایی و منابع اصلی تحقیق بود. یافته ها: نتایج نشان دهنده افزایش چشمگیر کاربرد تکنیک های یادگیری ماشینی و یادگیری عمیق در تشخیص کبد چرب غیرالکلی، به ویژه در دهه اخیر است. ایالات متحده، چین و هند به عنوان بزرگترین مشارکت کنندگان در این حوزه شناخته شدند. همچنین، اهمیت همکاری های بین المللی در پیشبرد این زمینه تحقیقاتی، از یافته های برجسته این مطالعه است. همکاری بین دانشگاه های برتر و گروه های تحقیقاتی بین المللی نقش کلیدی در پیشرفت این پژوهش ها ایفا کرده است. نتیجه گیری: این تحلیل علم سنجی نشان می دهد که هوش مصنوعی به سرعت در حال تغییر چشم انداز تشخیص بیماری NAFLD است. اگرچه پژوهش های اخیر به دقت های تشخیصی چشمگیری، به ویژه در مدل های یادگیری عمیق، دست یافته اند، اثرگذاری واقعی این فناوری در عمل بالینی به عواملی فراتر از عملکرد عددی وابسته است. روندهای پژوهشی حاکی از حرکت تدریجی از مدل های صرفاً دقیق به سوی سامانه های قابل تفسیر، قابل اعتماد و قابل پیاده سازی در بالین هستند. این نتایج بیانگر آن است که آینده تشخیص مبتنی بر هوش مصنوعی در NAFLD، در هم راستاسازی نوآوری فناوری با نیازهای واقعی بالینی نهفته است؛ مسیری که می تواند به تشخیص های عادلانه تر و کارآمدتر منجر شود.	نوع مقاله: مقاله پژوهشی دریافت: ۱۴۰۴/۸/۱۵ ویرایش: ۱۴۰۴/۱۲/۲۱ پذیرش: ۱۴۰۵/۱/۱۰ انتشار: ۱۴۰۵/۱/۲۶
---	--

واژگان کلیدی: یادگیری ماشین، یادگیری عمیق، بیماری کبد چرب غیرالکلی، تصویربرداری پزشکی

استناد: عادل سیاحی، سید عنایت الله علوی، مرتضی جادریان. مطالعه علم سنجی روش های یادگیری ماشین و یادگیری عمیق برای تشخیص بیماری کبد چرب غیرالکلی در تصویربرداری پزشکی. مجله علم سنجی کاسپین. ۱۴۰۵؛ ۱۳(۱): ۲۵-۱۲.




© The Author(s)

Publisher: Babol University of Medical Sciences

مقدمه

علم‌سنجی (Scientometrics) حوزه‌ای است که داده‌های علمی را با روش‌های کمی و کیفی اندازه‌گیری، ارزیابی و تحلیل می‌کند. این علم معمولاً برای ارزیابی پیشرفت علمی در یک کشور و یک حوزه خاص به کار می‌رود (۱). علم‌سنجی با بررسی مقالات علمی، محصولات و اختراعات ثبت‌شده در یک حوزه، میزان مشارکت کشورها در تولید علم جهانی را می‌سنجد (۲).

یادگیری ماشین (Machine Learning) و یادگیری عمیق (Deep Learning) در سال‌های اخیر به تصویربرداری پزشکی وارد شده و نقش مهمی در تشخیص و شناسایی بیماری کبد چرب غیرالکلی (Non-Alcoholic Fatty Liver) ایفا کرده‌اند. این بیماری در حدود ۲۵٪ از جمعیت جهان دیده می‌شود و یکی از علل اصلی بیماری‌های مزمن کبدی است (۳). کبد چرب غیرالکلی شامل تجمع چربی در کبد است که می‌تواند به سیروز و سرطان کبد منجر شود (۴). روش‌های سنتی تشخیص کبد چرب غیرالکلی مانند نمونه‌برداری کبدی تهاجمی، پرهزینه و همراه با عوارضی همچون خونریزی و عفونت هستند (۵). از این رو روش‌های غیرتهاجمی مانند سونوگرافی، تصویربرداری تشدید مغناطیسی (MRI) و توموگرافی کامپیوتری (CT scan) کاربرد گسترده‌ای یافته‌اند. شکل ۱ تصاویری که ابزارهای تشخیصی غیرتهاجمی را نشان می‌دهند. سونوگرافی به دلیل دسترسی آسان، رایج‌ترین روش تشخیصی است، اما در موارد خفیف دقت پایین‌تری دارد (۶). الگوریتم‌های پیشرفته ML و DL توانسته‌اند این محدودیت‌ها را کاهش و دقت تشخیص را افزایش دهند (۷ و ۸).



شکل ۱. تصاویر ابزارهای تشخیصی غیرتهاجمی (الف: سونوگرافی، ب: MRI، ج: سی‌تی‌اسکن) (۹)

مطالعات اخیر نشان می‌دهد که ادغام یادگیری ماشین مدل‌هایی با روش‌های تصویربرداری، تشخیص را تسریع می‌کنند و نتیجه دقیق‌تری را برای نتایج بهتر بیمار و بهبود در تصمیم‌گیری‌های بالینی ارائه می‌دهند (۱۰ و ۱۱). رویکردهای مبتنی بر یادگیری ماشین و یادگیری عمیق در تشخیص NAFLD از مدل‌های هوش مصنوعی استفاده می‌کنند که داده‌های تصویری مرتبط با این بیماری را تحلیل کرده و الگوهایی را شناسایی می‌کنند که ممکن است از دید متخصصان انسانی پنهان بماند.

مدل‌های یادگیری عمیق، مانند شبکه‌های عصبی پیچشی (Convolutional Neural Networks)، در وظایف مختلف طبقه‌بندی و قطعه‌بندی تصاویر پزشکی با موفقیت چشمگیری به کار گرفته شده‌اند و دقت بالایی در تشخیص استئاتوز و فیروز کبدی نشان داده‌اند (۱۲). این روش‌ها با کاهش خطای انسانی و تغییرات در تفسیر، نتایجی قابل‌اعتمادتر و تکرارپذیر ارائه می‌دهند (۱۳). همچنین، الگوریتم‌های دیگر یادگیری ماشین مانند ماشین‌های بردار پشتیبان (Support Vector Machine) و جنگل‌های تصادفی (Random forest) برای ترکیب داده‌های بالینی ساختاریافته با داده‌های تصویری غیرساختاریافته استفاده شده‌اند که این ترکیب دقت پیش‌بینی پیشرفت کبد چرب غیرالکلی را بهبود بخشیده است (۱۴). با افزایش شیوع کبد چرب غیرالکلی، علاقه به تشخیص‌های مبتنی بر هوش مصنوعی نیز رو به رشد است. این روند با افزایش تعداد مقالات علمی در زمینه کاربرد یادگیری ماشین و یادگیری عمیق در تشخیص بیماری‌های کبدی منعکس شده است. تحلیل‌های علم‌سنجی امکان ترسیم چشم‌انداز پژوهشی این حوزه را فراهم کرده و اطلاعاتی درباره روند انتشارات، شبکه‌های همکاری و تأثیر مطالعات کلیدی ارائه می‌دهند (۱۱). این تحلیل‌ها مشارکت‌کنندگان اصلی و زمینه‌های نوظهور تحقیقاتی را مشخص کرده و مسیرهایی برای پیشرفت‌های استراتژیک در استفاده از هوش مصنوعی در تشخیص بالینی بیماری‌های کبدی پیشنهاد می‌کنند.


تحلیل علم‌سنجی ابزاری مؤثر برای بررسی چشم‌انداز پژوهشی کاربرد مدل‌های هوش مصنوعی در تشخیص کبد چرب غیرالکلی است. این تحلیل‌ها به محققان امکان می‌دهد روند انتشارات، شبکه‌های همکاری و الگوهای استناد را ردیابی کنند تا افراد و مطالعات تأثیرگذار در این حوزه پویا را شناسایی کنند. برای مثال، مدل‌های یادگیری ماشین که بر داده‌های متنوعی مانند تصاویر سونوگرافی و پارامترهای بالینی آموزش دیده‌اند، دقت تشخیصی بین ۸۰٪ تا بیش از ۹۷٪ را در پیش‌بینی کبد چرب غیرالکلی نشان داده‌اند (۱۷-۱۵). این پیشرفت‌ها به‌ویژه با توجه به محدودیت‌های نمونه‌برداری کبد، اهمیت زیادی دارند و روش‌های غیرتهاجمی را به‌طور قابل‌توجهی بهبود بخشیده‌اند (۱۸). علاوه بر این، مطالعات نشان می‌دهند که روش‌های هوش مصنوعی

نه تنها دقت تشخیص را افزایش می دهند، بلکه امکان شناسایی نشانگرهای زیستی مرتبط با پیشرفت کبد چرب غیرالکلی را نیز فراهم می کنند (۱۹ و ۲۰). برای نمونه، پژوهش های اخیر با استفاده از یادگیری ماشینی در داده های لیپیدومیک و گلیکومیک، یافته های مهمی درباره علل بیماری و طبقه بندی شدت آن ارائه کرده اند (۲۱). همچنین، همکاری های بین رشته ای میان محققان، نوآوری هایی را در کاربردهای هوش مصنوعی به ارمغان آورده و منجر به توسعه سیستم های خودکار تشخیص و ارزیابی شدت کبد چرب غیرالکلی با حداقل دخالت انسانی شده است (۲۲).

با توجه به اهمیت بالای این موضوع، هدف اصلی پژوهش حاضر بررسی ویژگی ها و چشم انداز روندهای پژوهشی، روش شناسی های غالب و شبکه های همکاری در حوزه استفاده از هوش مصنوعی در تشخیص کبد چرب غیرالکلی از طریق تصویربرداری پزشکی طی سال های ۲۰۱۰ تا ۲۰۲۴ و ترسیم آینده این حوزه است.

مواد و روش ها

این مطالعه علم سنجی به تحلیل روندهای پژوهشی بین المللی و شبکه های همکاری در استفاده از یادگیری ماشینی و یادگیری عمیق برای تشخیص کبد چرب غیرالکلی از طریق روش های تصویربرداری پزشکی مانند سونوگرافی، MRI و سی تی اسکن می پردازد. بازه زمانی تحلیل، انتشارات علمی از سال ۲۰۱۰ تا ژوئن ۲۰۲۴ را در بر می گیرد. داده ها از چهار پایگاه اصلی؛ IEEE Xplore، PubMed، Scopus، Web of Science (WoS) و سال استخراج شدند. دلیل انتخاب این پایگاه ها پوشش کامل انتشارات داوری شده در حوزه های پزشکی، زیست شناسی و مهندسی است. شناسایی و انتخاب مقالات بر اساس دستورالعمل های PRISMA انجام شد. شکل ۲، جریان شناسایی تا ورود مقالات به مطالعه را مطابق با دستورالعمل PRISMA نشان می دهد.



شکل ۲. نمودار جریانی PRISMA برای جستجوی علمی تحقیق (نسخه رسمی PRISMA سال ۲۰۲۰ میلادی)

را هر دو جستجو شامل کلیدواژه های مرتبط با تشخیص NAFLD، هوش مصنوعی، یادگیری ماشینی، یادگیری عمیق و تصویربرداری پزشکی بود. هر پایگاه داده با پرسش های مشخص جستجو شد تا همه مطالعات مرتبط منتشر شده بین ۱ ژانویه ۲۰۱۰ تا ۱ ژوئن ۲۰۲۴ را پوشش دهد. کوئری های دقیق و تمرکز هر پایگاه در جدول ۱ خلاصه شده است.

سوابق انتشارات استخراج شده از این پایگاه ها در قالب استاندارد (CSV) صادر شدند تا تحلیل بیشتر روی آن ها انجام شود. نتایج جستجو برای حذف مقالات تکراری غربال شدند. همچنین مقالاتی که معیار ورود را نداشتند (مانند موارد غیرمرتبط با NAFLD، عدم تمرکز بر روش های مبتنی بر هوش

مصنوعی در تصویربرداری یا انتشار خارج از بازه زمانی مشخص شده) حذف شدند. در نهایت مجموعه نهایی شامل مقالاتی بود که به کاربرد روش‌های هوش مصنوعی، به‌ویژه یادگیری ماشینی و یادگیری عمیق، در تشخیص NAFLD در تصویربرداری پزشکی می‌پرداختند.

جدول ۱. پایگاه‌های داده کلیدی و عبارات جستجو

پایگاه داده	عبارت جستجو	تمرکز
Web of Science	TS=("Artificial Intelligence" OR "Machine Learning" OR "Deep Learning") AND TS=("Non-Alcoholic Fatty Liver Disease" OR "NAFLD") AND TS=("Ultrasound" OR "MRI" OR "CT" OR "Medical Imaging")	نمایه‌سازی استنادی چندرشته‌ای
Scopus	TITLE-ABS-KEY("Artificial Intelligence" OR "Machine Learning" OR "Deep Learning") AND TITLE-ABS-KEY("Non-Alcoholic Fatty Liver Disease" OR "NAFLD") AND TITLE-ABS-KEY("Ultrasound" OR "MRI" OR "CT" OR "Medical Imaging")	تحقیق در حوزه‌های دانشگاهی
PubMed	("Artificial Intelligence" OR "Machine Learning" OR "Deep Learning") AND ("Non-Alcoholic Fatty Liver Disease" OR "NAFLD") AND ("Ultrasound" OR "MRI" OR "CT" OR "Medical Imaging")	مطالعات زیست‌پزشکی و بالینی
IEEE Xplore	("Artificial Intelligence" OR "Machine Learning" OR "Deep Learning") AND ("Non-Alcoholic Fatty Liver Disease" OR "NAFLD") AND ("Ultrasound" OR "MRI" OR "CT" OR "Medical Imaging")	مهندسی و فناوری‌های مبتنی بر هوش مصنوعی

یافته‌ها

این بخش صرفاً بر اساس مرور ادبیات منتشر شده در پلتفرم‌های علمی درباره کاربرد روش‌های ML و DL در تشخیص NAFLD از طریق تکنیک‌های مختلف پردازش تصویر پزشکی مانند سونوگرافی، MRI و سی‌تی‌اسکن ارائه شده است. با به‌کارگیری روش‌های علم‌سنجی، روندهای پژوهشی در طول زمان، نویسندگان برجسته، توزیع جغرافیایی، شبکه‌های همکاری و موضوعات نوظهور مورد بررسی قرار گرفتند. یافته‌های اصلی در ادامه بیان می‌شوند. نتایج نشان می‌دهد روند انتشار مقالات مرتبط با تشخیص NAFLD به کمک هوش مصنوعی صعودی داشته و با گذر زمان افزایش یافته است. تحلیل بیشتر توزیع سالانه انتشارات بین سال‌های ۲۰۱۰ تا ۲۰۲۴ چشم‌انداز روشنی از تکامل فعالیت‌های پژوهشی ارائه می‌دهد. همچنین بررسی رشته‌های علمی محل انتشار این مقالات اهمیت دارد. همان‌طور که در جدول ۲ مشاهده می‌شود، بیشترین مقالات در حوزه تصویربرداری پزشکی و رادیولوژی منتشر شده‌اند.


جدول ۲. توزیع انتشارات بر اساس رشته تحصیلی

رشته	تعداد نشریات
تصویربرداری پزشکی	۳۲
سلامت / پزشکی	۹
علوم و مهندسی کامپیوتر	۲۳

این توزیع نشان‌دهنده ماهیت میان‌رشته‌ای پژوهش‌هاست و بیانگر همکاری میان علوم پزشکی و علوم فنی برای توسعه روش‌ها و کاربردهای نوآورانه است. شکل ۳، منحنی رشد نمایی انتشارات را نشان می‌دهد که با مفاهیم به‌دست‌آمده از حوزه‌های مختلف علمی تکمیل می‌شود و نرخ انتشارات سالانه و گسترش موضوعی را نمایان می‌سازد.

شناسایی مجلات علمی پیشرو، یکی از گام‌های اساسی در تحلیل ساختار انتشار دانش در حوزه کاربرد روش‌های هوش مصنوعی در تشخیص NAFLD محسوب می‌شود. نقشه‌برداری از مجلات پربازده امکان شناسایی مجلاتی را فراهم می‌کند که به‌عنوان هسته اصلی انتشار پژوهش‌ها در این حوزه عمل می‌کنند و نقش تعیین‌کننده‌ای در جهت‌دهی به جریان علمی دارند. مطابق نتایج ارائه‌شده در شکل ۴، مجله Radiology با بیشترین تعداد مقالات منتشر شده، در جایگاه نخست قرار دارد. این موضوع نشان‌دهنده نقش محوری این مجله در انتشار پژوهش‌های مرتبط با تصویربرداری پزشکی و کاربرد الگوریتم‌های هوش مصنوعی در تشخیص NAFLD است. پس از آن، مجلات Scientific Reports و European Radiology سهم قابل‌توجهی از تولیدات علمی را به خود اختصاص داده‌اند که بیانگر ماهیت بین‌رشته‌ای این حوزه و پیوند میان علوم داده، تصویربرداری پزشکی و بالینی است. در سطوح بعدی، مجلاتی نظیر AJR American Journal of Roentgenology و Ultrasound in Medicine and Biology مشاهده


می‌شوند که تمرکز آن‌ها بر روش‌های تصویربرداری تشخیصی، به‌ویژه سونوگرافی، نقش مهمی در توسعه مدل‌های هوش مصنوعی برای تشخیص غیرتهاجمی NAFLD ایفا کرده‌اند. همچنین حضور مجلات تخصصی حوزه کبد و گوارش از جمله *Journal of Gastroenterology and Hepatology* و *Clinical and Molecular Hepatology* نشان می‌دهد که نتایج این پژوهش‌ها به‌طور مستقیم مورد توجه جامعه بالینی نیز قرار گرفته است. به‌طور کلی، الگوی مشاهده‌شده در شکل ۴ حاکی از تمرکز انتشار مقالات در تعداد محدودی از مجلات با نفوذ بالا است که با اصول علم‌سنجی و قانون برادفورد همخوانی دارد. این یافته می‌تواند به‌عنوان راهنمایی عملی برای پژوهشگران جهت انتخاب مجلات هدف برای انتشار نتایج پژوهش‌های آتی مورد استفاده قرار گیرد.



شکل ۳. روند سالانه انتشار مقالات علمی مرتبط با تشخیص NAFLD از سال ۲۰۱۰ تا اول ژوئن ۲۰۲۴

● Radiology ● Sci Rep ● Eur Radiol ● European Radiology ● AJR Am J Roentgenol
 ● Ultrasound in Medicine and Biology ● Hepatol Commun ● IEEE International Ultrasonics Symposium, IUS
 ● J Gastroenterol Hepatol ● Clin Mol Hepatol

Journal




شکل ۴. مجلات علمی پیشرو در انتشار تحقیقات مرتبط با کاربرد روش‌های هوش مصنوعی در تشخیص NAFLD با استفاده از تصویربرداری پزشکی

علاوه بر مجلات، شناسایی نویسندگان پیشرو و پرکار، نقش مهمی در درک ساختار تولید دانش و شناسایی رهبران علمی این حوزه دارد. تحلیل نویسندگان امکان شناسایی پژوهشگرانی را فراهم می‌کند که بیشترین سهم را در توسعه و پیشبرد کاربرد روش‌های هوش مصنوعی در تشخیص NAFLD


داشته‌اند. مطابق شکل ۵، نویسندگانی نظیر Chen J و Wang Y با بالاترین تعداد مقالات، در صدر فهرست نویسندگان فعال قرار دارند. این موضوع نشان می‌دهد که این پژوهشگران نقش محوری در تولید دانش و توسعه روش‌های مبتنی بر یادگیری ماشین و یادگیری عمیق برای تحلیل تصاویر پزشکی مرتبط با NAFLD ایفا کرده‌اند.

در رتبه‌های بعدی، نویسندگانی مانند Zhang Y و Wong VW, Li X, Loomba R می‌شوند که عمدتاً دارای پیشینه بالینی در حوزه بیماری‌های کبدی هستند. این ترکیب از نویسندگان با تخصص‌های فنی و بالینی، بیانگر ماهیت بین‌رشته‌ای پژوهش‌ها و اهمیت همکاری میان متخصصان علوم داده و علوم پزشکی است. همچنین حضور نویسندگانی با تعداد مقالات کمتر اما مستمر، مانند Guo J, Tzur D, Almoznino G نشان‌دهنده شکل‌گیری شبکه‌ای از پژوهشگران فعال است که به‌صورت پیوسته در توسعه این حوزه مشارکت دارند. این شبکه‌ها نقش مهمی در تثبیت و گسترش مسیرهای پژوهشی آینده ایفا می‌کنند.




شکل ۵. نویسندگان برجسته فعال در حوزه پژوهش‌های هوش مصنوعی برای تشخیص NAFLD

از نظر جغرافیایی، توزیع فعالیت‌های پژوهشی نیز شایان توجه است. همان‌طور که در شکل ۶ دیده می‌شود، ایالات متحده (۳۱۳ مقاله)، چین (۱۸۶ مقاله) و هند (۶۷ مقاله) بیشترین سهم را در این حوزه داشته‌اند. همچنین کشورهایی مانند کانادا (۵۷ مقاله)، ایتالیا (۷۴ مقاله) و آلمان (۲۴ مقاله) نیز مشارکت قابل‌توجهی داشته‌اند.




شکل ۶. توزیع جهانی انتشارات در مورد کاربردهای هوش مصنوعی در تشخیص NAFLD در کشورهای مختلف


شبکه‌های همکاری نیز اهمیت زیادی دارند، چرا که نشان می‌دهند پژوهشگران، مؤسسات و کشورها چگونه با یکدیگر همکاری می‌کنند. شکل‌های ۷ تا ۹ نمودار شبکه همکاری را در پایگاه‌های IEEE Xplore، Scopus و Web of Science نمایش می‌دهند.



شکل ۷. همکاری علمی محققان شرکت‌کننده در تحقیقات هوش مصنوعی برای تشخیص NAFLD در پایگاه داده IEEE Xplore




شکل ۸. همکاری علمی محققان شرکت‌کننده در تحقیقات هوش مصنوعی برای تشخیص NAFLD در پایگاه داده Scopus



شکل ۹. همکاری علمی محققان شرکت‌کننده در تحقیقات هوش مصنوعی برای تشخیص NAFLD در پایگاه داده WOS

علاوه بر این، نقشه موضوعی ارائه‌شده در شکل ۱۰ حوزه‌ها را بر اساس دو بعد اهمیت و فعالیت دسته‌بندی می‌کند. نقشه موضوعی فوق با استفاده از تحلیل مؤلفه‌های اصلی (PCA) بر روی داده‌های مقالات پژوهشی ایجاد شده است. این ابزار با بهره‌گیری از کلمات کلیدی و داده‌های چکیده، خوشه‌های موضوعی کلیدی را شناسایی می‌کند. با اعمال روش خوشه‌بندی K-Means، موضوعات به چهار دسته اصلی تقسیم شده‌اند: موضوعات محرک، موضوعات خاص، موضوعات پایه و موضوعات نوظهور یا رو به زوال. این ابعاد از طریق خوشه‌بندی کلمه‌ها و تحلیل چکیده‌ها تعیین شده‌اند. خلاصه این دسته‌بندی در جدول ۳ آمده است.



شکل ۱۰. نقشه موضوعی خوشه‌ها و مضامین تحقیقاتی، استخراج‌شده با تحلیل PCA و خوشه‌بندی K-Means از داده‌های مقالات پژوهشی

جدول ۳. خلاصه نقشه موضوعی

موضوعات کلیدی	توضیحات	ربع دایره
یادگیری ماشین، یادگیری عمیق، NAFLD	مباحث محوری و بسیار فعال و اساسی در این حوزه	بالا راست (مضامین موتور)
چالش‌های منحصر به فرد یا بینش‌های خاص	مباحث تخصصی برای چالش‌های خاص	بالا چپ (مضامین خاص)
داده‌افزایی، یادگیری تخصصی	موضوعات جدید و نوآورانه یا در حال محو شدن	پایین چپ (مضامین نوظهور/رو به زوال)
تشخیص، پیش‌بینی، استخراج ویژگی	مفاهیم بنیادی که از پیشرفت‌ها در این زمینه پشتیبانی می‌کنند	پایین راست (مضامین پایه)

به‌طور خلاصه، نقشه موضوعی وضعیت کنونی پژوهش در این حوزه را نشان می‌دهد؛ این که کدام بخش‌ها فعال‌ترند، کدام تخصصی‌ترند و چه موضوعاتی در حال ظهور یا پایه‌ای هستند، همچنین تحلیل استنادات برای شناسایی روش‌ها و نویسندگان تأثیرگذار بسیار مهم است. شمارش استنادها بر اساس روش‌شناسی‌ها و نویسندگان، تأثیرگذارترین رویکردها و افراد کلیدی این حوزه را معرفی می‌کند. همان‌طور که در جدول ۴ نشان داده شده است، شبکه‌های CNN در میان روش‌های یادگیری عمیق بیشترین استناد را داشته‌اند:

جدول ۴. برترین روش‌شناسی‌ها بر اساس استنادات

روشناسی	الگوریتم	نویسنده‌ها	استنادها
DL	شبکه‌ی عصبی پیچشی	Graffy PM, Sandfort V, Summers RM, Pickhardt PJ	۹۹
DL	شبکه‌ی عصبی پیچشی	Han A, Byra M, Heba E, Andre MP, Erdman JW, et al.	۸۸
ML	جنگل تصادفی	Atabaki-Pasdar N, Ohlsson M, Viñuela A, Franks PW	۵۲
ML	ماشین‌های بردار پشتیبان	Acharya UR, Fujita H, Sudarshan VK, Mookiah MRK	۴۶
ML	درخت تصمیم (Decision Tree)	Acharya UR, Fujita H, Sudarshan VK, Mookiah MRK	۴۶
DL	شبکه‌ی عصبی پیچشی	Pickhardt PJ, Blake GM, Graffy PM, Sandfort V	۳۵
ML	جنگل تصادفی	Tang A, Destremes F, Kazemirad S, Garcia-Duitama J	۳۵
ML	رگرسیون لجستیک (Logistic Regression)	Liu Y-X, Liu X, Cen C, Li X, Liu J-M	۳۵
ML	XGBoost	Liu Y-X, Liu X, Cen C, Li X, Liu J-M	۳۵
ML	ماشین‌های تقویت‌کننده گرادینان (Gradient Boosting Machines)	Bashir MR, Wolfson T, Gamst AC, Fowler K	۳۱
DL	شبکه‌ی عصبی پیچشی	Byra M, Han A, Boehringer AS, Zhang YN	۲۹
DL	شبکه‌ی عصبی پیچشی	Constantinescu EC, Udriștoiu A-L, Udriștoiu CD	۲۴
ML	جنگل تصادفی	Destremes F, Gesnik M, Chayer B, Roy-Cardinal M-H	۲۳


بحث و نتیجه‌گیری

تحلیل چشم‌انداز پژوهشی در زمینه روش‌های مبتنی بر هوش مصنوعی برای تشخیص NAFLD بینش‌های مهمی درباره توسعه، چالش‌ها و روندهای آینده این حوزه میان‌رشته‌ای فراهم می‌کند. روش‌های ML و DL بیشترین استنادها را در ادبیات به خود اختصاص داده‌اند، به‌ویژه در زمینه تصویربرداری پزشکی برای NAFLD که طی دهه اخیر با افزایش انتشارات، همکاری‌های جهانی و پیشرفت‌های فناورانه همراه بوده است. یافته‌های کلیدی این مطالعه در جدول ۵ خلاصه شده‌اند.

جدول ۵. یافته‌های کلیدی از تحلیل

جنبه	مشاهده
روندهای انتشار	افزایش قابل توجه تعداد مقالات منتشرشده از سال ۲۰۱۶، به‌ویژه از سال ۲۰۱۸ به بعد، نشان‌دهنده افزایش علاقه به کاربردهای هوش مصنوعی برای بیماری کبد چرب غیرالکلی است.
توزیع جغرافیایی	ایالات متحده، چین و هند مشارکت‌کنندگان اصلی هستند و کشورهای اروپایی مانند ایتالیا و آلمان نیز سهم قابل‌توجهی در این امر دارند.
روش‌شناسی	رویکردهای یادگیری عمیق، به‌ویژه شبکه‌های عصبی پیچشی (CNNها)، به دلیل دقت برترشان در تشخیص مبتنی بر تصویر، غالب هستند.
شبکه‌های همکاری	همکاری‌های قوی بین‌المللی، به‌ویژه بین موسسات برتر در ایالات متحده، چین و هند، نوآوری در این زمینه را هدایت می‌کند.
مجلات و نویسندگان	مجلات بین‌رشته‌ای غالب هستند و نویسندگان برتر از هر دو زمینه پزشکی و مهندسی در آنها مشارکت دارند.
بیش‌های موضوعی	مضامین اصلی شامل تشخیص NAFLD، مدل‌های پیش‌بینی و استخراج ویژگی است، در حالی که مباحث نوظهور بر افزایش داده و یادگیری خصمانه تمرکز دارند.

چشم‌انداز جهانی پژوهش در زمینه کاربرد AI برای تشخیص NAFLD در حال حاضر تحت سلطه ایالات متحده و چین است. این دو کشور از چندین مزیت به‌هم‌پیوسته بهره‌مند هستند که آن‌ها را به پیشگامان این حوزه تبدیل کرده است. هر دو کشور منابع مالی قابل‌توجهی را به تحقیق و توسعه، به‌ویژه در کاربردهای هوش مصنوعی در حوزه سلامت، اختصاص داده‌اند. نهادهایی مانند مؤسسه ملی سلامت (National Institutes of Health) در ایالات متحده و برنامه‌های ملی تأمین مالی علم در چین، از پروژه‌های بزرگ‌مقیاس در زمینه یادگیری عمیق و تصویربرداری پزشکی به‌طور قابل‌توجهی حمایت کرده‌اند. وجود زیرساخت‌های پیشرفته بالینی و پژوهشی، از جمله دسترسی به منابع محاسباتی با کارایی بالا و مجموعه داده‌های بزرگ و حاشیه‌نویسی‌شده تصاویر پزشکی، پژوهشگران را قادر ساخته تا مدل‌های پیچیده هوش مصنوعی را توسعه داده و آموزش دهند (۲۳ و ۲۴). حمایت‌های سیاستی در سطح ملی برای تحول دیجیتال در حوزه سلامت در هر دو کشور، محیطی مناسب برای ادغام سیستم‌های هوشمند در جریان‌های کاری بالینی فراهم کرده است. علاوه بر این، جمعیت عظیم این کشورها نیاز عملی به ابزارهای تشخیصی خودکار و مقیاس‌پذیر را ایجاد کرده که می‌توانند تشخیص زود هنگام و پایش NAFLD را بهبود بخشند. در نهایت، اکوسیستم‌های همکاری قوی بین دانشگاه‌ها، بیمارستان‌ها و شرکت‌های فناوری، نوآوری و پیاده‌سازی در دنیای واقعی را تسریع کرده‌اند (۲۵). با وجود این پیشرفت‌ها، چالش‌های مهمی همچنان مانع پذیرش بالینی ابزارهای مبتنی بر هوش مصنوعی برای تشخیص NAFLD هستند. یکی از موانع اصلی، دسترسی محدود به مجموعه داده‌های بزرگ، استاندارد و چندمرکزی است. کمبود چنین داده‌هایی نه تنها آموزش مدل‌های قوی را محدود می‌کند، بلکه قابلیت تعمیم‌پذیری سیستم‌های هوش مصنوعی به جمعیت‌های متنوع را نیز کاهش می‌دهد. علاوه بر این، عدم تعادل در مجموعه داده‌ها، به‌ویژه کمبود داده‌های مربوط به مراحل پیشرفته NAFLD، منجر به ایجاد مدل‌های مغرضانه با دقت تشخیصی پایین‌تر در موارد شدید می‌شود (۲۶). مسئله دیگر، قابلیت تفسیر محدود مدل‌های یادگیری عمیق است. این مدل‌ها اغلب به‌عنوان جعبه‌های سیاه (Black box) در نظر گرفته می‌شوند که درک یا اعتماد به فرآیند تصمیم‌گیری آن‌ها برای پزشکان دشوار است.



شکل ۱۱. تکنیک‌های تفسیرپذیری و توضیح‌پذیری

مقاومت متخصصان مراقبت‌های بهداشتی، که اغلب ناشی از آشنایی محدود با ابزارهای هوش مصنوعی یا نگرانی در مورد قابلیت اطمینان آن‌هاست، مانع دیگری ایجاد می‌کند. همچنین، هزینه‌های بالای مرتبط با استقرار و نگهداری زیرساخت‌های هوش مصنوعی در محیط‌های بالینی می‌تواند به‌ویژه در

محیط‌های با منابع محدود، بازدارنده باشد. تکنیک‌های تفسیرپذیری می‌توانند به مدل‌های جعبه خاکستری اعمال شوند، در حالی که برای مدل‌های جعبه سیاه معمولاً از تکنیک‌های توضیح‌پذیری استفاده می‌شود.

برای غلبه بر این چالش‌ها، پژوهش‌های آینده باید بر چند جهت استراتژیک تمرکز کنند. توسعه مجموعه داده‌های بزرگ و حاشیه‌نویسی‌شده از طریق همکاری‌های بین‌المللی و چندمرکزی ضروری است. چنین مجموعه داده‌هایی استحکام و قابلیت تعمیم‌پذیری مدل‌های هوش مصنوعی را بهبود می‌بخشند. علاوه بر این، ادغام تکنیک‌های هوش مصنوعی قابل توضیح (Explainable Artificial Intelligence) مانند Grad-CAM و LIME، می‌تواند شفافیت را افزایش داده و شکاف بین خروجی‌های الگوریتمی و استدلال بالینی را پر کند (۲۳). مطالعات اعتبارسنجی واقعی و آینده‌نگر در محیط‌های بالینی نیز حیاتی هستند، زیرا بینش‌هایی در مورد قابلیت اطمینان، ایمنی و کاربردپذیری ابزارهای هوش مصنوعی در شرایط عملی ارائه می‌دهند. ایجاد چارچوب‌های گزارش‌دهی استاندارد برای ارزیابی مدل‌های هوش مصنوعی، مقایسه معنادار بین مطالعات را ممکن ساخته و فرآیندهای تأیید نظارتی را تسهیل می‌کند. در نهایت، استفاده از یادگیری انتقالی (Transfer Learning)، که امکان تنظیم دقیق مدل‌های از پیش آموزش‌دیده روی مجموعه داده‌های بزرگ را بر مجموعه داده‌های کوچکتر و خاص حوزه فراهم می‌کند، می‌تواند مشکلات کمبود داده را کاهش داده و توسعه مدل در پژوهش‌های NAFLD را تسریع کند (۲۵).

ارزیابی انتقادی مدل‌های مختلف هوش مصنوعی که برای تشخیص NAFLD استفاده می‌شوند، تفاوت‌های مهمی را در عملکرد، قابلیت تفسیر و کاربرد بالینی نشان می‌دهد. برای مثال، مدل‌های یادگیری عمیق مانند EfficientNet، به‌ویژه هنگامی که با ابزارهای تفسیری مانند Grad-CAM ترکیب شوند، دقت تشخیصی بالایی دارند که اغلب بیش از ۹۵٪ است (۲۴). با این حال، این مدل‌ها به منابع محاسباتی قابل توجه و دسترسی به مجموعه داده‌های متعادل و باکیفیت نیاز دارند. در مقابل، الگوریتم‌های یادگیری ماشینی کلاسیک مانند SVM و XGBoost، اگرچه دقت خام کمتری دارند، قابلیت تفسیر بهتری ارائه می‌دهند و نیازهای کمتری به داده و زیرساخت دارند. مطالعاتی که از XGBoost استفاده کرده‌اند، به‌ویژه زمانی که با ویژگی‌های بالینی و تصویربرداری ترکیب شوند، نتایج قابل‌اعتمادی با شفافیت بهبودیافته از طریق تفسیرهای مبتنی بر SHAP (SHapley Additive) (exPlanations) نشان داده‌اند (۲۶). علاوه بر این، استفاده از تکنیک‌هایی مانند SMOTE برای رفع عدم تعادل داده‌ها، حساسیت مدل به کلاس‌های کمتر نمایندگی‌شده را بهبود بخشیده است. در نهایت، موفقیت در انتقال این فناوری‌ها از پژوهش به عمل بالینی نه تنها به معیارهای عملکرد، بلکه به قابلیت توضیح، پذیرش توسط پزشکان و توانایی ادغام یکپارچه در جریان‌های کاری تشخیصی موجود وابسته است.

با وجود پیشرفت‌های چشمگیر در حوزه هوش مصنوعی و DL برای تشخیص بیماری‌ها، همچنان چالش‌های متعددی وجود دارد که مانع پذیرش گسترده این فناوری‌ها در محیط‌های بالینی می‌شود. مسائلی مانند بیش‌برازش (Overfitting)، عدم قابلیت تعمیم و سوگیری مدل‌ها همچنان بر استحکام و کاربردپذیری بالینی آن‌ها تأثیر می‌گذارند. غلبه بر این چالش‌ها مستلزم توسعه روش‌شناسی‌های نوآورانه، آزمون‌های دقیق و اصلاح مداوم است تا مدل‌های هوش مصنوعی نه تنها دقیق، بلکه قابل اعتماد و قابل استفاده برای جمعیت‌های گوناگون باشند.

با این حال، افق آینده بسیار امیدوارکننده است. مدل‌های پیشرفته‌ای همچون Vision Transformer (ViT) همراه با تکنیک‌های بهبود داده مانند شبکه‌های مولد تخصصی (GANs) برای تولید تصاویر پزشکی مصنوعی، ظرفیت بالایی برای رفع مشکلات موجود دارند. این ابزارها می‌توانند با افزایش انعطاف‌پذیری مدل‌ها و ایجاد داده‌های متنوع‌تر، تعمیم‌پذیری را بهبود دهند و از بیش‌برازش جلوگیری کنند. حوزه هوش مصنوعی در تصویربرداری پزشکی به سرعت در حال تحول است. ادغام این تکنیک‌های نوین می‌تواند دقت تشخیص‌ها را افزایش داده و سوگیری‌ها را کاهش دهد و در نهایت راه را برای نقش پررنگ‌تر AI در نظام سلامت هموار کند. آینده هوش مصنوعی در تصویربرداری پزشکی، به‌ویژه در بیماری‌های کبدی مانند NAFLD و دیگر اختلالاتی که از طریق سونوگرافی، MRI و سی‌تی‌اسکن تشخیص داده می‌شوند، بسیار روشن است.

چشم‌انداز خوش‌بینانه این است که با غلبه بر چالش‌های موجود، فرصت‌های جدیدی برای افزایش دقت تشخیص، کاهش نابرابری‌های بهداشتی و در نهایت بهبود پیامدهای بیماران ایجاد خواهد شد. با تلاش و نوآوری مستمر، آینده تشخیص‌های پزشکی مبتنی بر AI بسیار امیدوارکننده خواهد بود و این فناوری می‌تواند به‌طور یکپارچه وارد عمل بالینی شود و تحولی اساسی در نظام سلامت جهانی ایجاد کند.

ملاحظات اخلاقی: این مطالعه علم‌سنجی هیچ‌گونه آزمایش بر روی انسان یا حیوان را شامل نمی‌شود؛ بنابراین نیازی به دریافت تأییدیه اخلاقی نبود. تمام داده‌های تحلیل‌شده در این پژوهش از مطالعات منتشرشده پیشین و منابع در دسترس عموم استخراج شده‌اند.

تضاد منافع: نویسندگان هیچ‌گونه تعارض منافع مرتبط با انتشار این مقاله اعلام نمی‌کنند.

تقدیر و تشکر

این مقاله مستخرج از پایان‌نامه کارشناسی ارشد دانشگاه شهید چمران اهواز است. این پژوهش با پشتیبانی مالی دانشگاه شهید چمران اهواز و با شناسه گرنت SCU.EC1403.450 انجام شده است. بدین وسیله از دانشگاه شهید چمران اهواز تشکر و قدردانی به عمل می‌آید.

References

1. Rohra DK, Azam SI. Quantitative and qualitative analysis of PubMed-indexed biomedical publications in Oman from years 2005-2009. *Oman Med J*. 2011; 26(3): 160-5.
2. Sharifi V, Rahimi-Movaghar A, Mohammadi MR, Goodarzi RR, Izadian ES, Farhoudian A, et al. Analysis of mental health research in the Islamic Republic of Iran over 3 decades: a scientometric study. *Eastern Mediterranean Health Journal*. 2008; 14(5): 1060-9.
3. Younossi ZM, Koenig AB, Abdelatif D, Fazel Y, Henry L, Wymer M. Global epidemiology of nonalcoholic fatty liver disease—meta-analytic assessment of prevalence, incidence, and outcomes. *Hepatology*. 2016; 64(1): 73-84.
4. Chalasani N, Younossi Z, Lavine JE, Charlton M, Cusi K, Rinella M, et al. The diagnosis and management of nonalcoholic fatty liver disease: practice guidance from the American Association for the Study of Liver Diseases. *Hepatology*. 2018; 67(1): 328-57.
5. Rinella ME. Nonalcoholic fatty liver disease: a systematic review. *JAMA*. 2015; 313(22): 2263-73.
6. Petzold G. Role of Ultrasound Methods for the Assessment of NAFLD. *Journal of Clinical Medicine*. 2022; 11(15): 4581.
7. Liu J, Tian Y, Fu X, Mu C, Yao M, Ni Y, et al. Estimating global prevalence, incidence, and outcomes of non-alcoholic fatty liver disease from 2000 to 2021: systematic review and meta-analysis. *Chinese Medical Journal*. 2022; 135(14): 1682-91.
8. Khan Z, Ain HU, Faryal S, Inayat H, Ahmed F, Aijaz W. Frequency of NAFLD among Patients of Coronary Artery Disease. *Pakistan Journal of Medical & Health Sciences*. 2023; 17(02): 626.
9. Lee DH. Imaging evaluation of non-alcoholic fatty liver disease: focused on quantification. *Clin Mol Hepatol*. 2017; 23(4): 290-301.
10. Mantovani A, Byrne CD, Targher G. Efficacy of peroxisome proliferator-activated receptor agonists, glucagon-like peptide-1 receptor agonists, or sodium-glucose cotransporter-2 inhibitors for treatment of non-alcoholic fatty liver disease: a systematic review. *The Lancet Gastroenterology & Hepatology*. 2022; 7(4): 367-78.
11. Byra M, Szmigielski C, Kalinowski P, Paluszkiewicz R, Ziarkiewicz-Wróblewska B, Zieniewicz K, et al. Ultrasound-and biomarker-based assessment of hepatic steatosis in patients with severe obesity. *Pol Arch Intern Med*. 2023; 133(1).
12. Litjens G, Kooi T, Bejnordi BE, Setio AAA, Ciompi F, Ghafoorian M, et al. A survey on deep learning in medical image analysis. *Medical Image Analysis*. 2017; 42: 60-88.
13. Gulshan V, Peng L, Coram M, Stumpe MC, Wu D, Narayanaswamy A, et al. Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. *JAMA*. 2016; 316(22): 2402-10.
14. Choi SJ, Kim SM, Kim YS, Kwon OS, Shin SK, Kim KK, et al. Magnetic resonance-based assessments better capture pathophysiologic profiles and progression in nonalcoholic fatty liver disease. *Diabetes & Metabolism Journal*. 2021; 45(5): 739-52.
15. Gummadi S, Patel N, Naringrekar H, Needleman L, Lyshchik A, O’Kane P, et al. Automated machine learning in the sonographic diagnosis of non-alcoholic fatty liver disease. *Advanced Ultrasound in Diagnosis and Therapy*. 2020; 4(3): 176-82.

16. Okanoué T, Shima T, Mitsumoto Y, Umemura A, Yamaguchi K, Itoh Y, et al. Artificial intelligence/neural network system for the screening of nonalcoholic fatty liver disease and nonalcoholic steatohepatitis. *Hepatology Research*. 2021; 51(5): 554-69.
17. Atsawarungrangkit A, Laoveeravat P, Promrat K. Machine learning models for predicting non-alcoholic fatty liver disease in the general United States population: NHANES database. *World Journal of Hepatology*. 2021; 13(10): 1417.
18. Wang C, Yan J, Zhang S, Xie Y, Nie Y, Chen Z, et al. Screening new blood indicators for Non-alcoholic Fatty Liver Disease (NAFLD) diagnosis of Chinese based on machine learning. *Frontiers in Medicine*. 2022; 9: 771219.
19. Popa SL, Ismaiel A, Cristina P, Cristina M, Chiarioni G, David L, et al. Non-alcoholic fatty liver disease: implementing complete automated diagnosis and staging, a systematic review. *Diagnostics*. 2021; 11(6): 1078.
20. Zhang F, Zhang Z, Li Y, Sun Y, Zhou X, Chen X, et al. Integrated bioinformatics analysis identifies robust biomarkers and its correlation with immune microenvironment in nonalcoholic fatty liver disease. *Frontiers in Genetics*. 2022; 13: 942153.
21. Atabaki-Pasdar N, Ohlsson M, Viñuela A, Frau F, Pomares-Millan H, Haid M, et al. Predicting and elucidating the etiology of fatty liver disease: a machine learning modeling and validation study in the IMI DIRECT cohorts. *PLoS Medicine*. 2020; 17(6): e1003149.
22. Nduma BN, Al-Ajlouni YA, Njei B. The application of artificial intelligence (AI)-based ultrasound for the diagnosis of fatty liver disease: A systematic review. *Cureus*. 2023; 15(12): e50601.
23. Byra M, Styczynski G, Szmigielski C, Kalinowski P, Michałowski Ł, Paluszkiewicz R, et al. Transfer learning with deep convolutional neural network for liver steatosis assessment in ultrasound images. *Int J CARS*. 2018; 13(12): 1895-903.
24. Hu Q, Chen Y, Xiao J, Sun S, Chen J, Yuille AL, et al., editors. Label-free liver tumor segmentation. *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*; 2023. Available at: <https://doi.org/10.48550/arXiv.2303.14869>
25. Li X, Lan L, Lahza H, Yang S, Wang S, Yang W, et al. EAFP-Med: An efficient adaptive feature processing module based on prompts for medical image detection. *Expert Systems with Applications*. 2024; 247: 123334.
26. Dunn W, Alkhouri N, Yip TC, Castera L, Wong VW, Wong GL, et al. Su1537 machine learning advanced fibrosis and at-risk mash (aladdin) with a web-based calculator for probability prediction. *Gastroenterology*. 2024; 166(5): S-1629.