

Research Paper



Advances and Challenges of Artificial Intelligence in Diagnosing Non-Alcoholic Fatty Liver Disease: A Systematic Review

Fatimah shahhosseini¹, kimia zarooj hosseini², Amin Golabpour^{3*}

1. Master of Science , Department of Statistics, Allameh Tabatabaee University, Tehran, Iran.
2. Student Research Committee ,M.SC student, Medical Informatics, Department of Health Information Technology and Management, School of Allied Medical Sciences, Shahid Beheshti University of Medical Sciences, Tehran, Iran.
3. Department of Health Informatics Technology, School of Allied Medical Sciences, Shahroud University of Medical Sciences, Shahroud, Iran .

Use your device to scan
and read the article online

Citation shahhosseini, F. zarooj Hosseini K, Golabpour, A [Advances and Challenges of Artificial Intelligence in Diagnosing Non-Alcoholic Fatty Liver Disease: A Systematic Review (Persian)]. *Jundishapur Scientific Medical Journal*. 2025; 24(1):1-24. 1032592/jsmj.24.1.1

<https://doi.org/10.32592/jsmj.24.1.1>

ABSTRACT

Background and Objectives Non-alcoholic fatty liver disease (NAFLD) is one of the most common diseases worldwide. If not diagnosed and treated, the disease can progress and worsen. Currently, liver biopsy is the standard method for diagnosing NAFLD, though it has numerous limitations. Artificial intelligence (AI) algorithms can utilize clinical and imaging parameters to aid in the diagnosis of fatty liver disease. This study reviews AI-assisted diagnostic methods for fatty liver disease.

Subjects and Methods The present study is a systematic review of AI applications in diagnosing fatty liver disease. In the first phase, articles from citation databases were selected based on predefined criteria and then examined according to the algorithms used, types of data studied, involvement of clinical specialists, and clinical evaluation. Various evaluation parameters were used to assess the performance of the AI algorithms.

Results Researchers observed that, among the articles reviewed, 42% employed image processing, 58% relied on biomarkers, and in 84% of the studies, a specialist physician was involved. Nearly none of the studies included clinical evaluation, and most used black-box algorithms. Additionally, results from the T-TEST indicated no significant difference in AI performance between the two diagnostic approaches.

Conclusion AI significantly aids in diagnosing fatty liver disease; however, the lack of clinical evaluation and reliance on black-box algorithms pose challenges. These limitations significantly impact the current application of AI in clinical settings.

Keywords Non-alcoholic fatty acids, artificial intelligence, biomarkers, image processing

Received: 23 Sep 2024
Accepted: 27 nov 2024
Available Online: 20 may 2025

*** Corresponding Author: Amin Golabpour**

Address: Department of Health Informatics Technology, School of Allied Medical Sciences, Shahroud University of Medical Sciences, Shahroud, Iran

Tel: 09309206903

E-Mail: a.golabpour@shmu.ac.ir

Extended Abstract

Introduction

The Fatty liver disease, as it is defined by abnormal lipid accumulation in tissues in the liver, is one of the most common diseases worldwide. Initial diagnosis is challenging because no apparent symptoms are observed in its early stages. If not treated, it can progress to more severe health conditions like fibrosis, cirrhosis, or hepatocellular carcinoma (HCC). Currently, liver biopsy is the standard diagnosis technique; however, this technique has many drawbacks like needing patient consent, risks involved with potential perforation in the liver, very expensive in terms of cost, and variation in diagnosis assessments. Thus, it is essential to explore non-invasive methods in preventing and diagnosing fatty liver disease.

Algorithms in artificial intelligence have the ability to identify patterns and rules from various data sources that enable the development of diagnosis or treatment models with appropriate levels of effectiveness. Performance is evaluated by testing these models on new, unexperienced data to assess their sensitivity to specific challenges. AI algorithms can use both clinical and imaging parameters for diagnosing fatty liver, a topic that has received much attention due to its non-invasive nature. This research therefore seeks to carry out a systematic review of current developments on the use of AI algorithms in non-invasive diagnosis of non-alcoholic fatty liver disease (NAFLD).

Methods

This study is a systematic review that aims to evaluate the effectiveness of artificial intelligence in diagnosing fatty liver disease at its initial stages. First, references from databases like Scopus, PubMed, and Web of Science were gathered in adherence to specific predetermined criteria. Next, an assessment of parameters derived from relevant research papers took place. After compiling the data, papers that had been labeled as conference papers, not published in English, duplicates, or not directly related to AI-based diagnosis of fatty liver disease were removed from consideration. The included studies were ranked based on the type of algorithm used, whether clinical experts were involved in testing and clinical assessments, and whether the algorithm belonged to a black-box or white-box model.

To assess the performance of artificial intelligence algorithms, a series of performance metrics such as accuracy, area under the receiver operating characteristic curve (AUC), specificity, and sensitivity were investigated. Additionally, a t-test was used to evaluate the outcomes with respect to different factors.

Results

Subsequent to applying the specified inclusion and exclusion criteria, a total of 150 studies were derived from an initial collection of 700 articles. Analysis of these studies identified that 42% used image processing-based approaches, while 58% used biomarker-based approaches. Additionally, it was observed that 86% of studies used local data as opposed to 14% that used publicly available data. Additionally, 84% of articles included a clinical expert, with most of the models being based on black-box algorithmic architectures.

A comparative analysis of four measurement indicators with respect to image processing approaches and biomarker-based approaches has shown that image processing methods had greater accuracy compared to biomarker-based methods. This proves that, in research studies under analysis, image processing methods outperformed those that were based on biomarkers. However, results of t-tests had no statistically significant difference in artificial intelligence performance between both diagnosis approaches. Out of the algorithms used, Support Vector Machine (SVM), Random Forest (RF), and Logistic Regression (LR) were used most often because of their better classification performance.

Conclusion

The application of artificial intelligence in medical science is very beneficial in terms of more precision in diagnosis and treatment of diseases and a reduction in human error and better patient care. However, it is not without challenges and drawbacks. This research carries out a critical examination of AI-based methods for diagnosing non-alcoholic fatty liver disease (NAFLD). The outcomes reveal that the nature of algorithm used (black-box vs. white-box) affects diagnosis of diseases and should be a critical component in evaluating AI models. While AI-based diagnosis methods based on biomarkers and imaging modalities are very promising, a lack of clinical validation and predominance of black-box types are drawbacks that need to be overcome to make it more clinically relevant. In conclusion, as innovations in technology move towards more accurate artificial intelligence models, artificial intelligence is projected to be a valuable resource in non-invasive diagnosis of fatty liver and improve diagnosis and treatment approaches quite extensively.

Ethical Considerations

Compliance with ethical guidelines

The study is a review study and does not require an ethics code.

Funding

Not applicable

Authors contributions

A.G introduced and conceptualized the study idea. F.Sh developed the search strategy. Analysis of the articles was carried out by F.Sh and K. ZH and they wrote and revised the manuscript. A.G, F.Sh and K. ZH approved it.

Conflicts of interest

The authors declare that they have no competing interests.

Acknowledgements

The authors hereby sincerely thank the Vice Chancellor for Research of Shahrood University of Medical Sciences for their support in the research

مقاله پژوهشی

پیشرفت‌ها و چالش‌های هوش مصنوعی در تشخیص کبد چرب غیرالکلی: مرور نظام‌مند

فاطمه شاه‌حسینی¹، کیمیا زروج حسینی²، امین گلاب‌پور^{3*}

1. کارشناسی ارشد، گروه آمار، دانشگاه علامه طباطبایی، تهران، ایران.

2. کمیته تحقیقات دانشجویی، دانشجوی کارشناسی ارشد انفورماتیک پزشکی، گروه فناوری اطلاعات و مدیریت سلامت، دانشکده علوم پزشکی وابسته، دانشگاه علوم پزشکی شهید بهشتی، تهران، ایران.

3. گروه فناوری اطلاعات سلامت، دانشکده علوم پزشکی وابسته، دانشگاه علوم پزشکی شاهرود، شاهرود، ایران.

Use your device to scan
and read the article online

Citation shahhosseini, F. zaroj Hosseini K, Golabpour, A [Advances and Challenges of Artificial Intelligence in Diagnosing Non-Alcoholic Fatty Liver Disease: A Systematic Review (Persian)]. *Jundishapur Scientific Medical Journal*. 2025; 24(1):1-24. 10.32592/jsmj.24.1.24

doi <https://doi.org/10.32592/jsmj.24.1.1>

چکیده

زمینه و هدف کبد چرب غیرالکلی یکی از شایع‌ترین بیماری‌ها در جهان است. در صورت تشخیص ندادن و درمان نشدن، بیماری تشدید می‌شود. در حال حاضر بیوپسی کبد روش استاندارد برای تشخیص بیماری است که محدودیت‌های بسیاری دارد. الگوریتم‌های هوش مصنوعی می‌توانند از معیارهای بالینی و تصویربرداری برای تشخیص کبد چرب استفاده کنند. در این مطالعه به بررسی روش‌های تشخیص به کمک هوش مصنوعی پرداخته شده است.

روش بررسی مطالعه‌ی حاضر مرور سیستماتیک استفاده از هوش مصنوعی برای تشخیص بیماری کبد چرب است. در مرحله‌ی اول، مقالات در پایگاه‌های داده‌ی استنادی با معیارهای تعیین‌شده انتخاب و سپس براساس الگوریتم استفاده‌شده، نوع داده‌های مورد مطالعه، حضور متخصص بالینی و ارزیابی بالینی بررسی شدند. جهت سنجش عملکرد الگوریتم‌های هوش مصنوعی، از معیارهای مختلف ارزیابی استفاده شده است.

یافته‌ها پژوهشگران پس از بررسی مشاهده کردند که تشخیص در 42 درصد از مقالات با کمک پردازش تصویر و 58 درصد با کمک بیومارکرها بوده و 84 درصد از مقالات، پزشک متخصص حضور داشته است و تقریباً در هیچ مطالعه‌ای از ارزیابی بالینی استفاده نشده است و بیشتر، از الگوریتم‌های جعبه‌ی سیاه هستند. همچنین نتایج آزمون T-TEST آشکار کرد که عملکرد هوش مصنوعی در دو روش تشخیصی تفاوت زیادی با یکدیگر ندارد.

نتیجه‌گیری استفاده از هوش مصنوعی برای تشخیص بیماری کبد چرب کمک بسیار زیادی می‌کند؛ ولی عدم ارزیابی بالینی و استفاده از الگوریتم‌های جعبه‌ی سیاه، چالشی است که استفاده از الگوریتم‌ها با آن مواجه است و محدودیت‌های قابل توجهی برای کاربرد فعلی هوش مصنوعی در محیط‌های بالینی ایجاد می‌کند.

کلیدواژه‌ها کبد چرب غیرالکلی، هوش مصنوعی، بیومارکر، پردازش تصویر

تاریخ دریافت: 02 مهر 1403

تاریخ پذیرش: 07 آذر 1403

تاریخ انتشار: 31 اردیبهشت 1404

نویسنده مسئول:

امین گلاب‌پور

نشانی: شاهرود میدان هفتم تیر دانشگاه علوم پزشکی شاهرود

تلفن: 09309206903

رایانامه: a.golabpour@shmu.ac.ir.

مقدمه

هوش مصنوعی برای افزایش عملکرد و کارایی در بخش‌های مختلف تأکید می‌کند [10].

الگوریتم‌های هوش مصنوعی می‌توانند با استفاده از داده‌ها و روش‌های مختلف، الگوها و قوانین مرتبط با مسئله را یاد بگیرند و از این طریق مدل‌های تشخیصی یا درمانی با عملکرد مناسب ارائه کنند. این مدل‌ها با استفاده از داده‌های جدید که قبلاً ندیده‌اند، ارزیابی می‌شوند و قابلیت تطبیق خود را با توجه به نیاز مسئله نشان می‌دهند. برای مثال، در تشخیص بیماری، الگوریتم می‌تواند بیماران را با دقت بیشتری تشخیص دهد؛ به‌همین ترتیب، در مدلی که برای تشخیص افراد سالم طراحی شده است، الگوریتم می‌تواند در افزایش دقت برای تشخیص افراد سالم تنظیم شود [11-13].

الگوریتم‌های AI می‌توانند از معیارهای بالینی، آزمایشگاهی، اندوسکوپی و تصویربرداری برای تشخیص و مدیریت بیماری‌های کبدی و ضایعات جرمی استفاده کنند [4, 5, 14]. استفاده از این الگوریتم می‌تواند دقت و ثبات را در تشخیص بیماری‌ها در مقایسه با تشخیص براساس تفسیر انسانی بهبود بخشد [15].

مقالات مروری، نقش قابل‌توجه AI را در زمینه بهبود شناسایی، تشخیص و مدیریت NAFLD جهت جایگزین عمل‌های تهاجمی، نشان می‌دهد [16, 17].

بیشتر مطالعات مروری در حوزه کبد چرب، بر بخش تشخیص تمرکز داشته‌اند. تعداد کمی از مطالعات وجود دارد که در آن‌ها به پیش‌بینی پاسخ به درمان، پرداخته شده است.

در مطالعه‌ای که در سال 2022 انجام شده [15]، کاربرد AI برای ارزیابی کبد چرب غیرالکلی و تمایز ضایعات کبدی متمرکز معرفی شده است و از عملکرد AI مبتنی بر سونوگرافی، در پیش‌بینی اثر درمانی، پروگنوز و نفوذ میکروواسکولار در کارسینوما هیپاتوسولولار بحث شده است. الگوریتم‌های AI می‌توانند تصاویر سونوگرافی را تجزیه و تحلیل کنند تا ناهنجاری‌های مرتبط با بیماری‌های کبدی مانند فیروز و استئاتوز را شناسایی کنند.

در مطالعه‌ای که در سال 2022 انجام شده [18] سوابق بهداشتی الکترونیک و تکنیک‌های تحلیل تصویر خودکار، برای تشخیص بیماری کبد با به‌کارگیری روش‌های AI بررسی شد که در آن رگرسیون لجستیک برای accuracy بالا و ماشین‌های بردار پشتیبانی برای specificity بالا در تشخیص NAFLD تأکید شده است.

در مطالعه‌ای در سال 2021 [19]، شاخص‌های مبتنی بر خون و تصویربرداری با الگوریتم‌های AI برای تشخیص بیماری کبد چرب بررسی

حدود 25 درصد از افراد جهان با وجود مصرف کم الکل تحت‌تأثیر بیماری کبدی قرار گرفته‌اند [1]. کبد چرب که تجمع بیش از حد چربی در کبد است، یکی از شایع‌ترین بیماری‌های کبدی در سراسر جهان شناخته می‌شود و تشخیص زودهنگام و دقیق این بیماری چالش‌برانگیز است؛ زیرا مراحل اولیه‌ی آن معمولاً بدون علامت است [2]. ۳۳/۹ درصد از جمعیت آسیایی طی سال‌های 2012 تا 2017 به بیماری کبد چرب غیرالکلی (NAFLD) مبتلا بوده‌اند [3]. افزایش شیوع بیماری کبد چرب غیرالکلی (NAFLD) یک چالش برای سیستم‌های پزشکی فعلی به شمار می‌رود. در صورت عدم تشخیص و درمان بیماری NAFLD، می‌تواند به سمت فیروز، سیروز و کارسینوما هیپاتوسولولار (HCC) پیشرفت کند [4]. بیوپسی کبد یک روش استاندارد تشخیص NASH است که برای غربالگری روتین مناسب نیست [5]. بیوپسی کبد محدودیت‌هایی از جمله پذیرش بیمار، خطر سوراخ شدن، هزینه‌ی اقتصادی، تنوع تشخیصی و ... دارد؛ بنابراین، بررسی راه‌حل‌هایی برای پیشگیری و درمان به‌صورت غیرتهاجمی بسیار مهم است.

هوش مصنوعی (AI) در سال‌های اخیر به‌سرعت در بسیاری از جنبه‌های پزشکی از جمله شناسایی تصویر، تشخیص غیرتهاجمی و تصمیم‌گیری درمانی در حال توسعه است [6, 7]. این مدل‌ها نسبت به مدل‌های آماری در به تصویر کشیدن تعاملات پیچیده و پیوندهای غیرخطی که بین متغیرها و نتایج وجود دارد، عملکرد بهتری دارند [8].

الگوریتم‌های هوش مصنوعی، به‌ویژه آن‌هایی که در حوزه‌ی یادگیری عمیق و یادگیری ماشینی هستند، مزایای قابل‌توجهی نسبت به روش‌های سنتی در کاربردهای مختلف، به‌ویژه در مراقبت‌های بهداشتی و مهندسی نشان داده‌اند. یکی از مزایای کلیدی توانایی آن‌ها در تجزیه و تحلیل مجموعه‌داده‌های بزرگ با ابعاد بالا و استخراج الگوهای پیچیده است که اغلب با تکنیک‌های مرسوم نادیده گرفته می‌شوند. برای مثال، مدل‌های یادگیری عمیق در مراقبت‌های بهداشتی نشان داده‌اند که با بهبود دقت پیش‌بینی به‌طور قابل‌توجهی از روش‌های رگرسیون سنتی بهتر عمل می‌کنند، مطالعات نشان می‌دهد که هنگام استفاده از تکنیک‌های یادگیری عمیق در مقایسه با تحلیل‌های رگرسیون خطی، دقت تا ۴۰ درصد بیشتر است [9]. افزون‌براین، الگوریتم‌های هوش مصنوعی، مانند شبکه‌های عصبی و درخت‌های تصمیم تقویت‌شده، ثابت کرده‌اند که فرایندهای تشخیصی را بهبود می‌بخشند که در آن، تشخیص خطا و تشخیص ریشه‌ای بهبود یافته، منجر به زمان پاسخ‌دهی سریع‌تر و کاهش هزینه‌های تعمیر و نگهداری می‌شود. این پیشرفت‌ها بر تأثیر تحول‌آفرین فناوری‌های

شده است.

2024/4/24 خلاصه کرده است. هدف از این مقاله، ارائه دیدگاهی جامع درباره‌ی پیشرفت‌های کنونی و چشم‌اندازهای آینده در این حوزه و همچنین بررسی چالش‌ها و محدودیت‌های موجود برای استفاده از AI برای تشخیص کبد چرب است. از طریق این بررسی، امیدواریم که بتوانیم به افزایش آگاهی میان جامعه‌ی پزشکی کمک کنیم و گامی به سوی بهبود روش‌های تشخیصی و درمانی برداریم.

روشن بررسی

مطالعه‌ی حاضر یک مطالعه‌ی مروری سیستماتیک است که با هدف ارزیابی اثربخشی هوش مصنوعی برای تشخیص زودهنگام کبد چرب انجام شده است. در مرحله‌ی اول با استفاده از پایگاه‌های اطلاعاتی استنادی و براساس معیارهای ازپیش‌تعیین‌شده، تعدادی مطالعه استخراج و در مرحله‌ی دوم معیارهای استخراج‌شده از مطالعات ارزیابی شده‌اند.

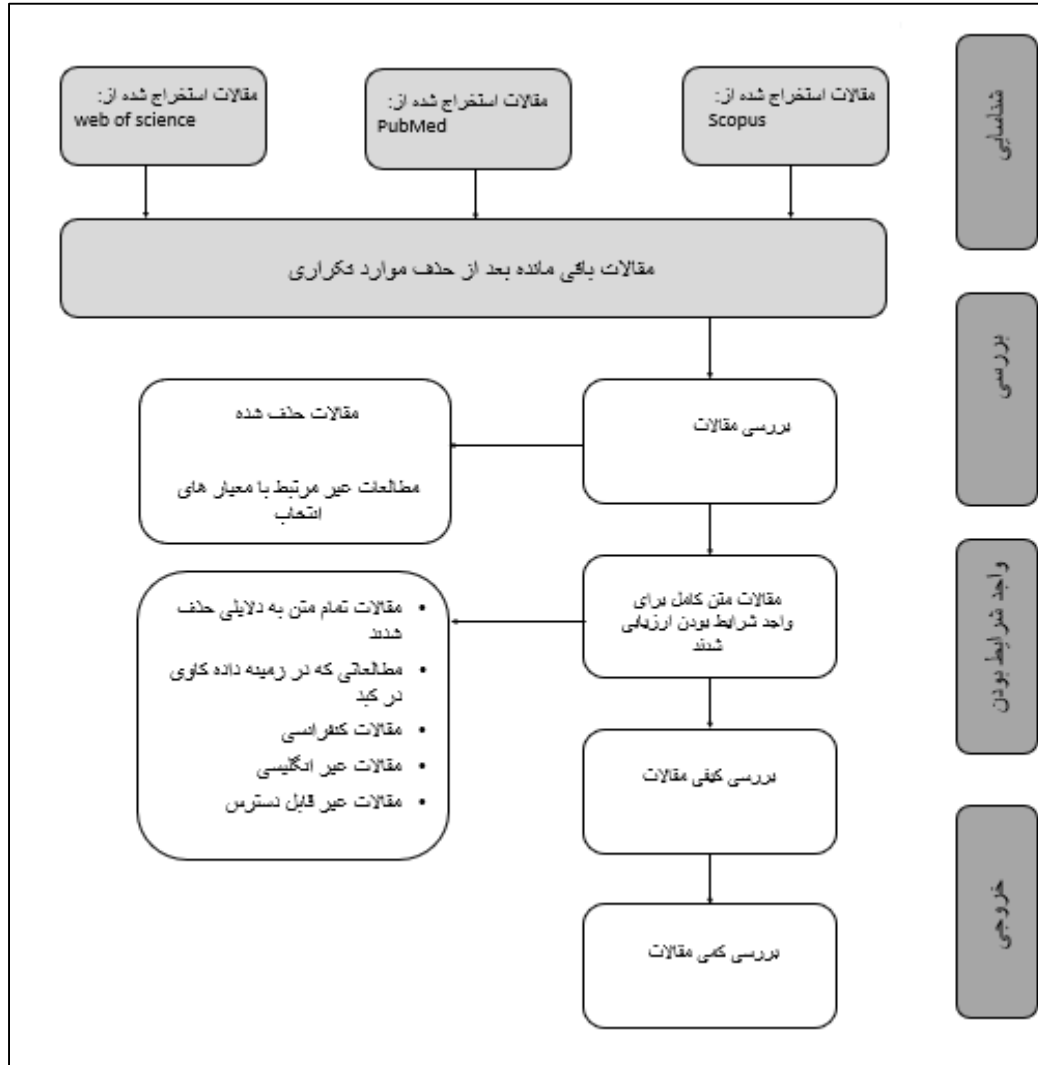
جهت جستجو در پایگاه‌های استنادی سه کلمه‌ی تشخیص، کبد چرب و هوش مصنوعی به‌عنوان کلمات کلیدی انتخاب و سپس کلمات مشابه استخراج شده است. در ادامه با کمک کلمات به‌دست‌آمده‌ی متن پرس‌وجو آماده و در پایگاه‌های web of science، scopus، pubmed جستجو شد. در استراتژی جستجو، برای بازیابی مقالات مرتبط حوزه، مفاهیم سه حوزه با استفاده از عملگرهای بولین با همدیگر ترکیب شدند (جدول 1، استراتژی جستجوی پایگاه‌های داده).

پس از گردآوری مطالعات، مطالعاتی از مجموعه‌مقالات انتخابی حذف شدند که عبارت‌اند از: مقالات کنفرانسی، غیرانگلیسی، تکراری و مقالاتی که ارتباط مستقیم به تشخیص کبد چرب از طریق هوش مصنوعی نداشتند (شکل ۱).

در مقاله‌ی در سال 2016 [20] ابتدا ظاهر ناهنجاری‌های کبدی در تصاویر اولتراسوند توصیف و مسائل عملی درباره‌ی شناسایی بیماری‌های پراکنده‌ی کبدی که می‌توانند با الگوریتم‌های نرم‌افزاری بررسی شوند، بیان شده‌اند؛ سپس به‌طور کلی درباره‌ی تشخیص کمکی با ویژگی‌ها و طبقه‌بندی‌های مرتبط با بیماری‌های پراکنده‌ی کبدی (که در آن بیشترین مورد طبقه‌بندی از شبکه‌ی عصبی استفاده شده است) بحث شده است.

در مطالعه‌ی که در سال 2024 انجام شد [16] خلاصه‌ای جامع از شواهد فعلی درباره‌ی نقش تشخیصی، پیش‌آگهی یا درمانی AI در بیماری کبد چرب ارائه شده است که به تفاوت‌های موجود بین مطالعات اشاره دارد. استاندارد طلایی یا معیارهای مرجع میان مطالعات متفاوت است. برای مثال، در برخی مطالعات از هیستولوژی به‌مثابه‌ی معیار تشخیصی برای NAFLD استفاده می‌شود، اما در مقالات دیگر از تصویربرداری یا داده‌های بالینی استفاده می‌شود. نوع طبقه‌بندی‌کننده‌ی AI میان مطالعات متفاوت است. برای مثال، در برخی مطالعات فقط از شبکه‌های عصبی مصنوعی (ANN) استفاده می‌شود، اما در مطالعات دیگری چندین روش یادگیری ماشین مقایسه می‌شوند. همچنین نوع روش AI میان مطالعات متفاوت است. برای مثال، در برخی مطالعات از داده‌های بالینی و آزمایشگاهی برای ایجاد مدل‌های AI برای ارزیابی پیش‌آگهی سیروز کبدی استفاده شده است، اما در مقالات دیگر از تصویربرداری استفاده شده است. افزون‌براین، به پیشرفت‌های بیشتری برای عملکرد تشخیصی و پیش‌بینی‌کننده‌ی AI نیاز است.

این مقاله‌ی مروری، آخرین تحقیقات استفاده از AI را، به‌ویژه یادگیری ماشینی، برای تسهیل تشخیص، پیش‌بینی و نظارت بر NAFLD، تا تاریخ



شکل ۱- راهبرد یافتن مقالات

پژوهش، تقسیم‌بندی از نظر جعبه‌ی سفید یا سیاه بودن الگوریتم استفاده‌شده در تشخیص، نوع الگوریتم‌های استفاده‌شده و ارزیابی بالینی مقالات است.

سپس مقالات تجزیه و تحلیل شدند. معیارهای این تحلیل شامل نوع داده‌های مورد استفاده، حضور یا عدم حضور پزشک در تیم

جدول 1. استراتژی جستجوی پایگاه‌های داده

تاریخ جستجو	عبارت جستجو	پایگاه داده
2024/4/24	(Diagnosis[tiab] OR Diagnoses[tiab] OR Diagnose[tiab]) AND ('Fatty Liver'[tiab] OR Steatohepatitis[tiab] OR 'Visceral Steatosis'[tiab] OR 'Visceral Steatoses'[tiab] OR 'Liver Steatosis'[tiab] OR 'Liver Steatoses'[tiab]) AND ('Intelligence Artificial'[tiab] OR 'Computational Intelligence'[tiab] OR 'Machine Intelligence'[tiab] OR 'Computer Reasoning'[tiab] OR 'Computer Vision Systems'[tiab] OR 'Knowledge Acquisition'[tiab] OR 'Knowledge Representation'[tiab] OR 'Knowledge Representations'[tiab] OR 'Machine Learning'[tiab] OR 'Transfer Learning'[tiab] OR 'Decision Tree'[tiab] OR 'Random Forests'[tiab])	pubmed

OR 'Expert Systems'[tiab] OR 'Neural Networks'[tiab] OR 'support vector machine'[tiab] OR 'k-means'[tiab] OR 'Connectionist Models'[tiab] OR 'Supervised Learning'[tiab] OR 'Unsupervised Learning'[tiab] OR 'Reinforcement Learning'[tiab] OR 'deep learning'[tiab] OR 'image processing'[tiab])

scopus	TITLE-ABS (diagnosis OR diagnoses OR diagnose) AND TITLE-ABS ("Fatty Liver" OR "Visceral Steatosis" OR "Visceral Steatoses" OR "Liver Steatosis" OR "Liver Steatoses") AND TITLE-ABS ("Intelligence Artificial" OR "Computational Intelligence" OR "Machine Intelligence" OR "Computer Reasoning" OR "Computer Vision Systems" OR "Knowledge Acquisition" OR "Knowledge Representation" OR "Knowledge Representations" OR "Machine Learning" OR "Transfer Learning" OR "Decision Tree" OR "Random Forests" OR "Expert Systems" OR "Neural Networks" OR "support vector machine" OR "k-means" OR "Connectionist Models" OR "Supervised Learning" OR "Unsupervised Learning" OR "Reinforcement Learning" OR "deep learning" OR "image processing")	2024/4/24
web of scienc	TS=(Diagnosis OR Diagnoses OR Diagnose) AND TS=("Fatty Liver" OR "Visceral Steatosis" OR "Visceral Steatoses" OR "Liver Steatosis" OR "Liver Steatoses") AND TS=("Intelligence Artificial" OR "Computational Intelligence" OR "Machine Intelligence" OR "Computer Reasoning" OR "Computer Vision Systems" OR "Knowledge Acquisition" OR "Knowledge Representation" OR "Knowledge Representations" OR "Machine Learning" OR "Transfer Learning" OR "Decision Tree" OR "Random Forests" OR "Expert Systems" OR "Neural Networks" OR "support vector machine" OR "k-means" OR "Connectionist Models" OR "Supervised Learning" OR "Unsupervised Learning" OR "Reinforcement Learning" OR "deep learning" OR "image processing")	2024/4/24

آزمون آماری t-test استفاده شد.

در ارزیابی اثربخشی الگوریتم‌های هوش مصنوعی، معیارهای مختلفی مانند دقت، مساحت سطح زیر منحنی ROC (AUC)، ویژگی و حساسیت استفاده شد (جدول 2). همچنین جهت تجزیه و تحلیل نتایج حاصل از متغیرها از

جدول 2. فرمول‌های معیارهای ارزیابی

فرمول

معیار

$$\frac{TP+TN}{TP+FN+FP+TN}$$

دقت (accuracy)

$$\frac{TP}{TP+FN}$$

حساسیت (sensitivity)

$$\frac{TN}{FP+TN}$$

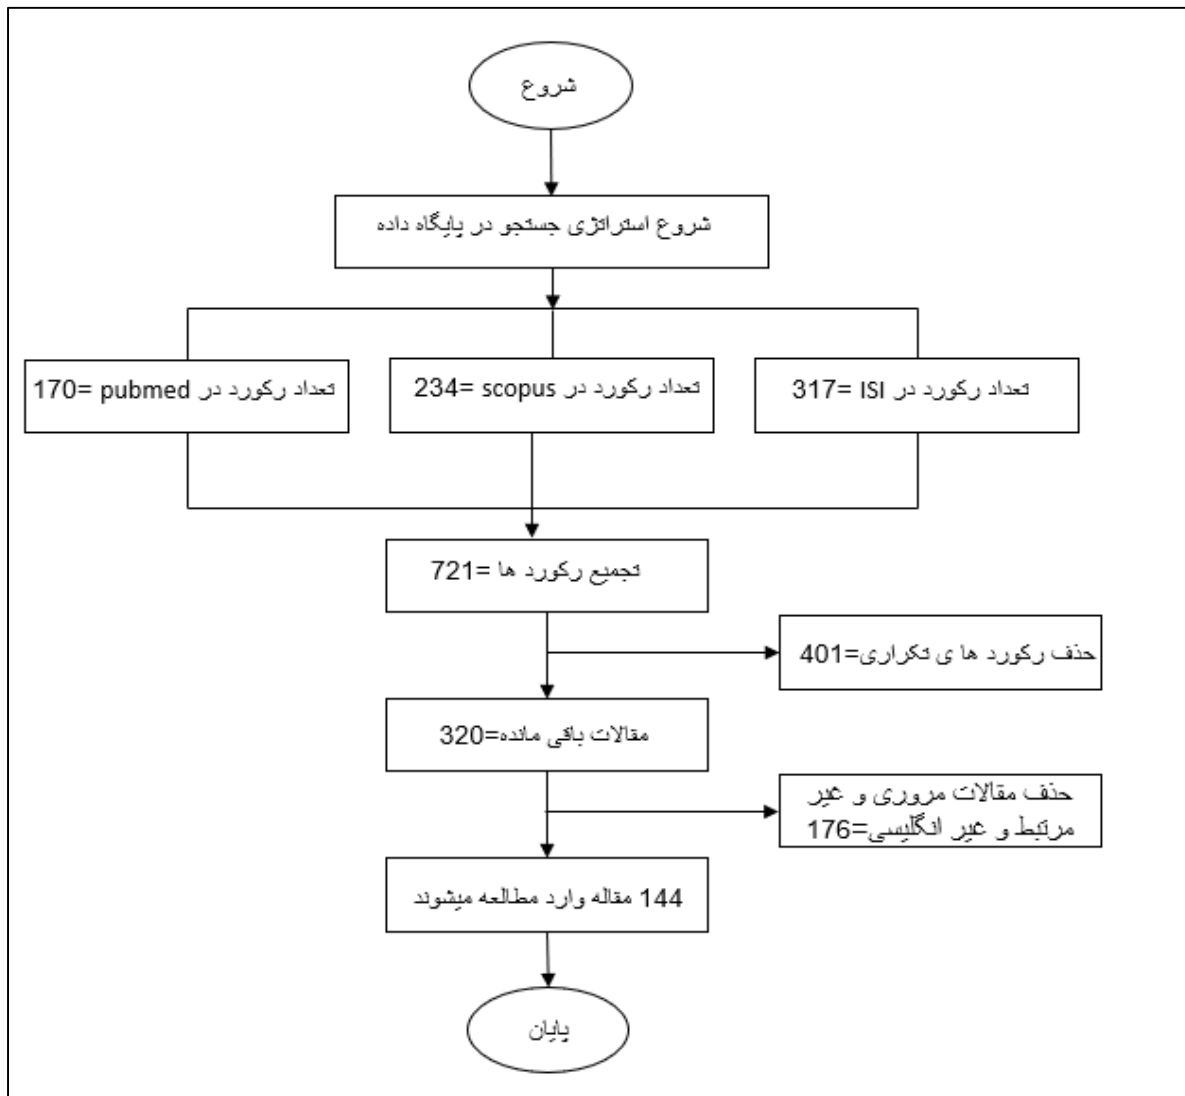
ویژگی (specificity)

$$\frac{TP}{TP+FP}$$

درستی (precision)

یافته‌ها

پس از بررسی‌های انجام‌شده براساس پرس‌وجوی نوشته‌شده در سه پایگاه داده، جستجو مطابق با تصویر 2 است. برای پایگاه داده scopus، 234 مقاله و 170 مقاله، web of scienc، 317 مقاله استخراج شد و بعد از حذف موارد تکراری و در نظر گرفتن معیار ورود و خروج، 144 مقاله [21-164] تجزیه و تحلیل شد و معیارهای مختلف استخراج شدند (تصویر ۲).




شکل 2 فرایند انتخاب مقالات

شامل 42 درصد و 58 درصد از کل مقالات شده است. بررسی‌ها نشان‌دهنده‌ی آن است که در 86 درصد از مطالعات، از داده‌های محلی و در 14 درصد از داده‌های عمومی استفاده شده است (شکل ۳، بخش الف). همچنین در 84 درصد

نتایج بررسی‌های انجام‌شده در مقالات آشکار کرد که در آن‌ها، برای تشخیص از دو روش پردازش تصویر و اندازه‌گیری بیومارکرها استفاده شده است که به ترتیب

موارد مطالعه، پزشک به عنوان نویسنده در گروه تحقیق حضور داشته است (شکل ۳، بخش ب). در این مطالعه 91 درصد مقالات از الگوریتم‌های جعبه سیاه و 9 درصد از مقالات از الگوریتم‌های سفید استفاده کرده‌اند. درخت تصمیم و سیستم‌های مبتنی بر قانون از موارد الگوریتم‌های جعبه سیاه بوده‌اند (شکل ۳، بخش ج).



ب) مقایسه حضور یا عدم حضور پزشک




الف) مقایسه داده‌های استفاده شده

در بررسی مطالعات، چهار معیار ارزیابی، برای مقایسه‌ی دو رویکرد استفاده از پردازش تصویر و داده‌های بیومارکر استفاده شده است. نتایج بیانگر آن است که دقت داده‌های پردازش تصویر در مجموع بالاتر از دقت داده‌های بیومارکر است و آشکار کرد که روش‌های پردازش تصویر در این مجموعه مقاله‌ی خاص عملکرد بهتری نسبت به روش‌های مبتنی بر بیومارکر دارند. پراکندگی مقادیر دقت در داده‌های پردازش تصویر کمتر از داده‌های بیومارکر است که نشان می‌دهد تنوع کمتری در عملکرد روش‌های پردازش تصویر در این مجموعه داده وجود دارد (شکل ۴، الف).

مقادیر مساحت سطح زیر نمودار ROC (AUC) برای تشخیص با کمک داده‌های بیومارکر، پراکندگی بیشتری نسبت به تشخیص با کمک پردازش تصویر داشته است. AUC داده‌های پردازش تصویر به‌طور کلی بالاتر از AUC داده‌های بیومارکر است که نشان می‌دهد که روش‌های پردازش تصویر در این مجموعه مقاله‌ی خاص عملکرد بهتری نسبت به روش‌های مبتنی بر بیومارکر دارند (شکل ۴، ب). ویژگی داده‌های پردازش تصویر به‌طور کلی بالاتر از ویژگی داده‌های بیومارکر است که نشان می‌دهد که روش‌های پردازش تصویر در این مطالعه تمایل کمتری به طبقه‌بندی نادرست موارد منفی به‌مثابه‌ی مثبت دارند. پراکندگی مقادیر ویژگی در داده‌های پردازش تصویر کمتر از داده‌های بیومارکر است که نشان می‌دهد که تنوع کمتری در عملکرد روش‌های پردازش تصویر در این مجموعه داده وجود دارد (شکل ۴، ج).

درستی در داده‌های پردازش تصویر از پراکندگی بیشتری برخوردار است؛ ولی مقادیر آن بین چارک‌های اول و سوم، مقدار بیشتری را نسبت به رویکرد داده‌محور دارد و می‌توان گفت که تنوع بیشتری در عملکرد پردازش تصویر دیده می‌شود (شکل ۴، د).

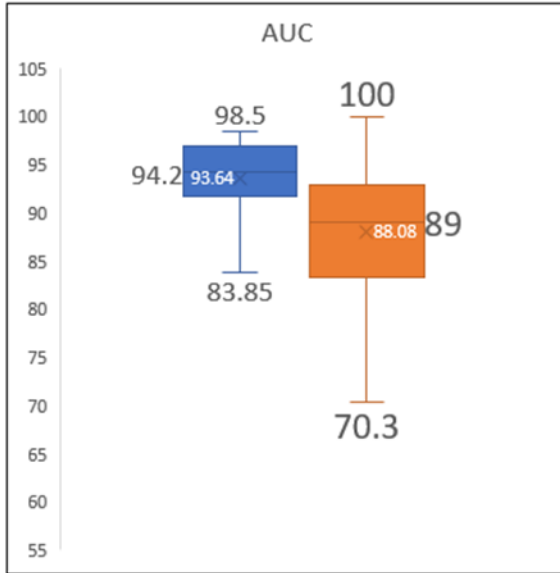


ج) مقایسه نوع الگوریتم استفاده شده


شکل ۳. مقایسه‌ی فراوانی معیارهای مختلف

می‌دهد که تنوع کمتری در عملکرد روش‌های پردازش تصویر در این مجموعه داده وجود دارد (شکل ۴، ۵).

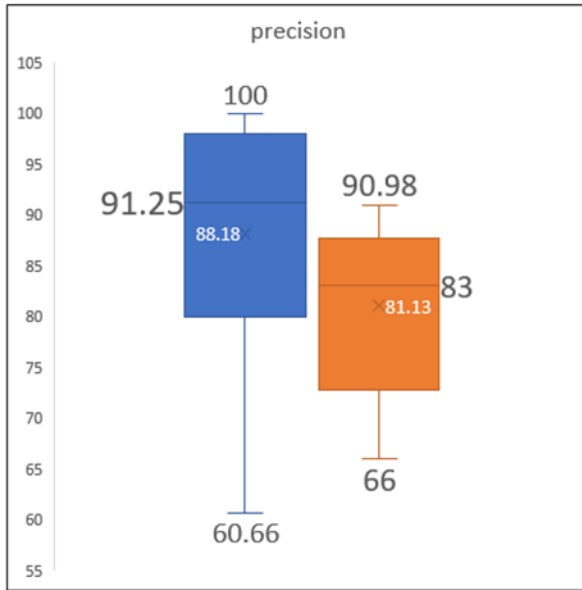
حساسیت داده‌های پردازش تصویر به‌طور کلی بالاتر از حساسیت داده‌های بیومارکر است که نشان می‌دهد روش‌های پردازش تصویر در این مقالات، تمایل کمتری به طبقه‌بندی نادرست موارد مثبت به‌عنوان منفی دارند. پراکندگی مقادیر حساسیت در داده‌های پردازش تصویر، کمتر از داده‌های بیومارکر است که نشان



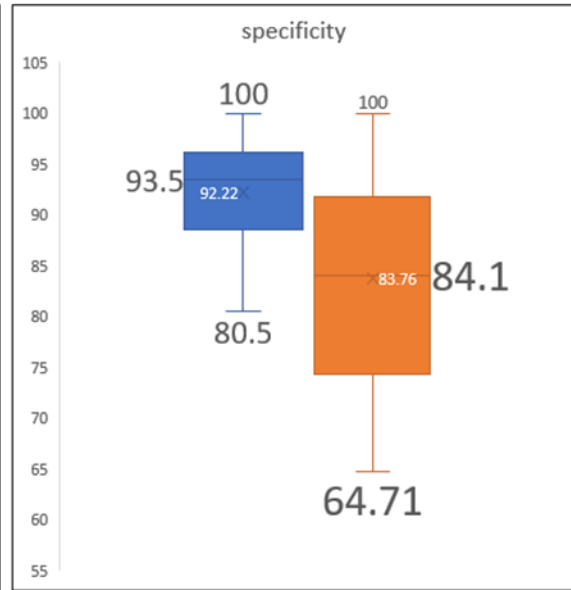
ب) مقایسه‌ی AUC داده‌ی تشخیص بیومارکر و پردازش تصویر



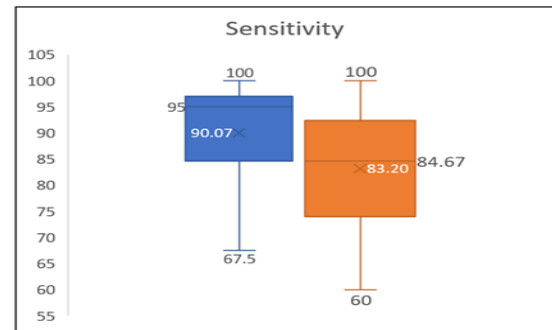
الف) مقایسه‌ی صحت داده‌ی تشخیص بیومارکر و پردازش تصویر



د) مقایسه‌ی دقت داده‌ی تشخیص بیومارکر و پردازش



ج) مقایسه‌ی ویژگی داده‌ی تشخیص بیومارکر و پردازش

ه) مقایسه‌ی حساسیت داده‌ی تشخیص بیومارکر و پردازش
تصویر 4

تصویر وجود ندارد و زمانی که از هوش مصنوعی برای تشخیص استفاده می‌شود، تفاوت زیادی بین دو روش تشخیصی وجود ندارد (جدول 3).

نتایج استخراج شده از بررسی چهار معیار، تفاوت بین روش تشخیص را با کمک بیومارکرها و پردازش تصویر بیان می‌کند؛ اما باید معنادار بودن این تفاوت بررسی شود؛ بنابراین، از آزمون t-test استفاده شد و نتایج تجزیه و تحلیل داده‌ها، آشکار کرد که اختلاف معناداری بین روش تشخیص براساس داده‌ی بیومارکر و پردازش

شده است. همچنین، شش معیار آماری شامل حداقل، حداکثر، میانگین، واریانس، انحراف معیار و دامنه تغییرات محاسبه و در جدول 4 به تفصیل آورده شده‌اند.

جدول 4. آمار توصیفی معیارهای مقالات تشخیص کبد چرب از دو دیدگاه پردازش تصویر و بیومارکر

کمترین	بیشترین	میانگین	واریانس	انحراف استاندارد	دامنه
داده‌ها	70/1	100	87/7	68/6	36/9
پردازش تصویر	84	98/5	94/0.23	13/63	14/5
داده‌ها	71/6	98	84/9	54/9	26/4
پردازش تصویر	61/6	100	92/17	51/9	38/4
داده‌ها	60	100	83/2	144/65	40
پردازش تصویر	67/5	100	90/0.7	94/69	32/5
داده‌ها	64/7	100	83/8	106/8	35/2
پردازش تصویر	80/5	100	92/2	31/6	19/5
داده‌ها	66	90/98	81/13	57/6	24/9
پردازش تصویر	60/6	100	88/18	140/64	39/34

بحث

مقالات داشته‌اند، تمامی الگوریتم‌ها از نوع الگوریتم‌های جعبه‌ی سیاه است و این الگوریتم‌ها معمولاً مدل‌های پیچیده‌ی یادگیری ماشینی هستند که عملکرد درونی آن‌ها به راحتی توسط انسان قابل تفسیر نیست و دارای عملکرد بالا و شفافیت پایین است؛ به همین دلیل، در بالین قابل استفاده نیست و در بررسی انجام شده، 91 درصد از مقالات از این الگوریتم‌ها استفاده کرده‌اند. الگوریتم‌های تشخیص بیماری کبد چرب، علاوه بر تشخیص ابتلا، باید توانایی بیان علت هر تشخیص را داشته باشد تا بتوان به طور گسترده از آن استفاده کرد.

الگوریتم‌های طبقه‌بندی نقش مهمی در حوزه‌ی پزشکی دارند و ابزارهای قدرتمندی برای تجزیه و تحلیل داده‌های بیمار و کمک به تصمیم‌گیری بالینی ارائه می‌کنند. برای دسته‌بندی داده‌ها، کلاس‌های از پیش تعریف شده براساس ویژگی‌های ورودی طراحی شده‌اند [165]. استفاده از الگوریتم‌های طبقه‌بندی برای مراقبت‌های بهداشتی در زمینه‌هایی مانند تشخیص بیماری، پیش‌بینی درمان و طبقه‌بندی بیمار کمک می‌کند و در نهایت نتایج بیمار را از طریق بینش‌های مبتنی بر داده‌ها بهبود می‌بخشد [166، 167]. الگوریتم ماشین بردار پشتیبان (SVM) به دلیل دقت بالای آن در کارهای طبقه‌بندی، به طور فزاینده‌ای در زمینه‌ی پزشکی برای کاربردهای تشخیصی مختلف استفاده می‌شود.

هدف از این مطالعه، مرور بر مطالعاتی درباره‌ی استفاده از یادگیری ماشین برای تشخیص کبد چرب غیرالکلی است تا بتوان دیدگاهی جامع درباره‌ی پیشرفت‌های کنونی و چشم‌اندازهای آینده در این حوزه ارائه کرد و همچنین به بررسی چالش‌ها و محدودیت‌های موجود در استفاده از AI برای تشخیص کبد چرب پرداخت. استفاده از هوش مصنوعی (AI) در علم پزشکی می‌تواند مفید باشد؛ زیرا در تشخیص و درمان بیماری‌ها، کاهش خطاها و ارائه‌ی پشتیبانی به بیمار کمک می‌کند. از طرفی هم می‌تواند چالش‌ها و نگرانی‌هایی را ایجاد کند. نوع الگوریتم استفاده شده (از لحاظ جعبه‌ی سیاه یا سفید) نیز می‌تواند در تشخیص بیماری تأثیرگذار باشد و باید به آن به مثابه‌ی یکی از عوامل مؤثر برای ارزیابی و استفاده از مدل ارائه شده توجه کرد.

پس از جستجو در پایگاه‌های متعدد داده و لحاظ معیارهای ورود و خروج بر 700 مطالعه، 150 مقاله بررسی شد. مقالات در دو دسته‌ی تشخیص با کمک پردازش تصویر و تشخیص با کمک بیومارکرها تقسیم‌بندی شد و نتایج، بیان‌کننده‌ی آن بود که 42 درصد از مقالات درباره‌ی پردازش تصویر و 58 درصد درباره‌ی بیومارکرها بوده‌اند. پس از محاسبه‌ی معیارهای مختلف، نتایج آشکار کرد که الگوریتم‌های ماشین‌های بردار پشتیبان (SVM)، جنگل تصادفی (Random Forest) و رگرسیون لجستیک (LR) بیشترین تکرار را میان

ابتلا به بیماری دیابت است؛ زیرا پزشکان نقش مهمی در ارزیابی‌های بالینی هوش مصنوعی (AI) در محیط‌های مراقبت‌های بهداشتی ایفا می‌کنند. حضور پزشکان متخصص، جهت ارزیابی ایمنی، کارایی و پیامدهای عملی ابزارهای هوش مصنوعی ضروری است؛ زیرا آن‌ها تخصص بالینی و درک مراقبت از بیمار را به فرایند ارزیابی وارد می‌کنند [175]. مشارکت پزشکان نه تنها در ارزیابی اولیه، بلکه در نظارت مداوم سیستم‌های هوش مصنوعی ضروری است تا اطمینان حاصل شود که آن‌ها همچنان نیازهای بالینی را برآورده می‌کنند و بر مراقبت از بیمار یا رابطه‌ی پزشک و بیمار تأثیر منفی نمی‌گذارند [176]. در بررسی مقالات، نتایج بیان‌کننده‌ی آن بود که در 84 درصد از مقالات، پزشک در تیم پژوهشی حضور داشته است. معیارهای ارزیابی هوش مصنوعی (AI) به دلیل تضمین ایمنی و تأثیر ابزارهای هوش مصنوعی در بهبود عملکرد بالینی در بالین از اهمیت حیاتی برخوردار هستند [177]؛ درحالی‌که هوش مصنوعی برای بهبود تشخیص و مراقبت از بیمار مؤثر است، چالش‌هایی مانند سوگیری الگوریتم، حریم خصوصی داده‌ها و ماهیت جعبه‌ی سیاه برخی از مدل‌های هوش مصنوعی، تناقضات بالقوه‌ای را با کارایی و قابل اعتماد بودن آن‌ها در عمل بالینی نشان می‌دهد [178]. هوش مصنوعی، به‌ویژه یادگیری ماشین (ML)، اغلب با توانایی آن در تشخیص الگوها و روابط پیچیده در داده‌ها مشخص می‌شود که ممکن است به‌آسانی برای رویکردهای آماری مرسوم آشکار یا قابل دسترسی نباشد [180.179]. در مقالات بررسی‌شده، 4 معیار ارزیابی AUC، Accuracy، specificity و sensitivity در نظر گرفته شده است که نتایج معیار ارزیابی نشان داده است که AUC و accuracy، Sensitivity، Specificity، داده‌های پردازش تصویر به‌طور کلی بالاتر از داده‌های بیومارکر است که نشان می‌دهد که روش‌های پردازش تصویر در این مجموعه‌مقاله‌ی خاص عملکرد بهتری نسبت به روش‌های مبتنی بر بیومارکر دارد [181]؛ اما پس از بررسی معنادار بودن این تفاوت، نتایج آشکار کرد که تفاوت معناداری بین داده‌ها وجود ندارد و استفاده از هوش مصنوعی برای تشخیص بیماری کبد چرب به کمک داده‌ی بیومارکر یا پردازش تصویر، به‌تنهایی قدرت تفکیک مناسبی دارد؛ هرچند برای این مسئله نیاز به مطالعه و پژوهش‌های بیشتر برای اثبات آن است. به‌دلیل نبود داده دربارهِ بیماری مشابه، در داده‌های استفاده‌شده‌ی مدل‌ها، می‌تواند باعث ایجاد خطا برای تشخیص‌های بیماری‌های مشابه شود؛ بنابراین، پیشنهاد می‌شود در داده‌های استفاده‌شده از داده‌های بیماری‌های کبدی مشابه با هم استفاده شود تا دقت مدل در زمان تشخیص بالاتر برود. ادغام هوش مصنوعی (AI) در پزشکی چالش‌ها و محدودیت‌های متعددی را به همراه دارد و برای اطمینان از اجرای مؤثر باید به‌دقت به آن توجه شود. یکی از نگرانی‌های اصلی حفظ حریم خصوصی و امنیت داده‌ها است؛ زیرا ماهیت حساس اطلاعات پزشکی نیازمند اقدامات سختگیرانه برای محافظت از محرمانه بودن اطلاعات بیمار و مطابقت با استانداردهای نظارتی است [182]. افزون‌براین، پتانسیل سوگیری الگوریتمی

SVM به‌ویژه برای مدیریت مجموعه‌داده‌های پیچیده مؤثر است و آن را برای تشخیص بیماری‌هایی مانند سرطان و ذات‌الریه مناسب می‌کند. برای مثال، از آن برای طبقه‌بندی داده‌های پزشکی مانند مجموعه‌داده‌های سرطان و دیابت از طریق معیارهای بهینه استفاده شده است و عملکرد پیش‌بینی مدل‌ها را افزایش می‌دهد. افزون‌براین، SVM با استفاده از تکنیک‌های پیشرفته‌ی یادگیری ماشین که با الگوریتم‌های انتخاب ویژگی ادغام شده است، شناسایی افراد مبتلا را با دقت قابل توجهی بهبود می‌بخشد و با موفقیت در تشخیص بیماری‌هایی مانند گلوکوم استفاده شده است [168]. سازگاری SVM با سناریوهای مختلف پزشکی، آن را یک ابزار حیاتی برای مراقبت‌های بهداشتی معرفی کرده است که به تشخیص‌های سریع‌تر و قابل اطمینان‌تر کمک می‌کند [169]. الگوریتم جنگل تصادفی یک تکنیک یادگیری گروهی قوی است که به‌طور گسترده در زمینه‌ی پزشکی برای کاربردهای مختلف، به‌ویژه برای تشخیص و پیش‌بینی بیماری‌ها استفاده می‌شود. این روش درخت‌های تصمیم‌گیری چندگانه را در طول آموزش می‌سازد و خروجی‌های آن‌ها را برای تولید پیش‌بینی‌های دقیق‌تر و قابل اعتمادتر ادغام می‌کند. در تنظیمات پزشکی، Random Forest برای کارهایی مانند پیش‌بینی سرطان سینه به کار گرفته شده است، تا جایی که در ترکیب با تکنیک‌های متعادل‌سازی داده‌ها مانند SMOTE به دقت 89 درصد دست یافته است [170]. افزون‌بر این، الگوریتم در مدیریت مجموعه‌داده‌های نامتعادل برتر است و آن را برای تجزیه و تحلیل سوابق پزشکی پیچیده مناسب می‌کند. نقاط قوت آن شامل دقت پیش‌بینی بالا، تحمل نویز و توانایی مدیریت داده‌های چندبعدی است که ویژگی‌های ضروری برای بهبود نتایج تشخیصی در مراقبت‌های بهداشتی هستند [171]. الگوریتم رگرسیون لجستیک (LR) یک روش آماری پرکاربرد در زمینه‌ی پزشکی برای کارهای طبقه‌بندی باینری است، مانند پیش‌بینی وجود یا نبود یک بیماری براساس ویژگی‌های بالینی مختلف. این الگوریتم با مدل‌سازی احتمال یک نتیجه‌ی خاص با استفاده از یک تابع لجستیک، که ترکیب خطی متغیرهای ورودی را به مقداری بین 0 و 1 تبدیل می‌کند، عمل می‌کند؛ بنابراین، برای نتایج باینری مناسب می‌شود [172]. LR با موفقیت در مطالعات متعددی برای پیش‌بینی شرایطی مانند بیماری قلبی، دیابت و سرطان سینه به کار گرفته شده است که نشان‌دهنده‌ی اثربخشی در شناسایی عوامل خطر مهم و کمک به تشخیص زود هنگام است. سادگی، تفسیرپذیری و توانایی آن برای کنترل متغیرهای پیوسته و توانایی طبقه‌بندی، رگرسیون لجستیک را به یک ابزار ضروری در تحقیقات پزشکی و عملکرد بالینی تبدیل می‌کند [173.174]. داده‌های استفاده‌شده در مطالعات بررسی‌شده به دو صورت داده‌ی آزادانه و داده‌ی محلی تقسیم‌بندی می‌شود که در 86 درصد، داده‌ی محلی استفاده شده است و در 14 درصد داده‌ی عمومی بررسی شده است. استفاده از داده‌های عمومی باعث کاهش تعمیم‌پذیری الگوریتم می‌شود. معیار دیگری که در این مقالات بررسی شد، حضور حداقل یک متخصص بالینی در مقالات پیش‌بینی

توسط فاطمه شاه‌حسینی و کیمیا زروج حسینی انجام شد و دستنویس را نوشتند و تصحیح کردند. امین گلاب‌پور، فاطمه شاه‌حسینی و کیمیا زروج حسینی آن را تایید کرد.

تعارض منافع

هیچ‌گونه تعارض منافی وجود ندارد.

تشکر و قدردانی

بدین‌وسیله نویسندگان از معاونت پژوهشی دانشگاه علوم پزشکی شاهرود جهت حمایت‌های خود در امر پژوهش صمیمانه تشکر می‌کنند.

می‌تواند بر دقت تشخیصی تأثیر منفی بگذارد، به‌ویژه در جمعیت‌هایی که کمتر نشان داده شده‌اند که منجر به نابرابری در نتایج مراقبت‌های بهداشتی می‌شود [183]. افزون‌بر آن، نیاز به مجموعه‌داده‌های بزرگ و باکیفیت برای آموزش مدل‌های هوش مصنوعی، موانع لجستیکی ایجاد می‌کند، به‌ویژه در زمینه‌هایی که جمع‌آوری داده‌ها محدود است یا در معرض بررسی‌های نظارتی است. برای مثال مدل‌های ML و یادگیری عمیق به مجموعه‌داده‌های بزرگی برای طبقه‌بندی یا پیش‌بینی دقیق وظایف مختلف نیاز دارند [184]. بخش‌هایی که ML پیشرفت چشمگیری داشته است، بخش‌هایی هستند که مجموعه‌داده‌های بزرگی برای فعال کردن الگوریتم‌های پیچیده‌تر و دقیق‌تر دردسترس دارند؛ اما داده‌های بهداشتی گران هستند و بی‌میلی نسبت به به اشتراک‌گذاری داده‌ها بین بیمارستان‌ها وجود دارد؛ زیرا آن‌ها دارایی هر بیمارستان برای مدیریت بیماران خود در نظر گرفته می‌شوند [185]. همچنین نگرانی‌هایی درباره‌ی تفسیرپذیری مدل‌های هوش مصنوعی وجود دارد، زیرا بسیاری از الگوریتم‌های پیشرفته به‌مثابه‌ی جعبه‌ی سیاه عمل می‌کنند و درک و اعتماد به توصیه‌های آن‌ها را برای متخصصان مراقبت‌های بهداشتی دشوار می‌کند. پرداختن به این چالش‌ها برای به‌کارگیری پتانسیل کامل هوش مصنوعی برای بهبود مراقبت از بیمار و کارایی عملیاتی و درعین‌حال حصول اطمینان از رعایت استانداردهای اخلاقی بسیار مهم است [186].

نتیجه‌گیری

نتایج آشکار می‌کند که به‌طور کلی عملکرد هوش مصنوعی در دو روش تشخیص، براساس داده‌ی بیومارکر و پردازش تصویر قابل‌قبول است و در مواردی که پزشک در تشخیص خود احتمال بیماری را می‌دهد، انتخاب روش تشخیص تفاوتی ندارد؛ اما زمانی که پزشک، بیشتر احتمال سالم بودن بیمار را می‌دهد، استفاده از روش پردازش تصویر مناسب‌تر است؛ اما به‌طور کلی استفاده از روش پردازش تصویر هزینه‌ی بیشتری دارد؛ بنابراین، انتخاب نوع روش تشخیص باید در اختیار پزشک قرار گیرد.

ملاحظات اخلاقی

پیروی از اصول اخلاق پژوهش

مطالعه حاضر مروری بوده و به کد اخلاق نیاز ندارد.

حامی مالی

این مطالعه حامی مالی نداشته است.

مشارکت نویسندگان

امین گلاب‌پور ایده مطالعه را معرفی و مفهوم سازی کرد. فاطمه شاه‌حسینی استراتژی جستجو را توسعه داد، تجزیه و تحلیل مقالات

References

- [1]Younossi Z, Tacke F, Arrese M, Chander Sharma B, Mostafa I, Bugianesi E, et al. Global Perspectives on Nonalcoholic Fatty Liver Disease and Nonalcoholic Steatohepatitis. *Hepatology*. 2019;69(6):2672-82.[[10.1002/hep.30251](https://doi.org/10.1002/hep.30251)][[PMID](https://pubmed.ncbi.nlm.nih.gov/31111111/)]
- [2]Grissa D, Nytoft Rasmussen D, Krag A, Brunak S, Juhl Jensen L. Alcoholic liver disease: A registry view on comorbidities and disease prediction. *PLoS Comput Biol*. 2020;16(9):e1008244.[[10.1371/journal.pcbi.1008244](https://doi.org/10.1371/journal.pcbi.1008244)][[PMID](https://pubmed.ncbi.nlm.nih.gov/32888888/)]
- [3]Lee JS, Kim ES, Moon WJCe. Chronological review of endoscopic indices in inflammatory bowel disease. 2019;52(2):129-36[[10.5946/ce.2018.042](https://doi.org/10.5946/ce.2018.042)][[PMID](https://pubmed.ncbi.nlm.nih.gov/31111111/)]
- [4]Lupsor-Platon M, Serban T, Silion AI, Tirpe GR, Tirpe A, Florea M. Performance of Ultrasound Techniques and the Potential of Artificial Intelligence in the Evaluation of Hepatocellular Carcinoma and Non-Alcoholic Fatty Liver Disease. *Cancers (Basel)*. 2021;13(4):790.[[10.3390/cancers13040790](https://doi.org/10.3390/cancers13040790)][[PMID](https://pubmed.ncbi.nlm.nih.gov/34444444/)]
- [5]Zhang L, Mao Y, editors. Artificial intelligence in NAFLD: will liver biopsy still be necessary in the future? *Healthcare*; 2022: MDPI.[[10.3390/healthcare11010117](https://doi.org/10.3390/healthcare11010117)][[PMID](https://pubmed.ncbi.nlm.nih.gov/36666666/)]
- [6]Zhou J, Du M, Chang S, Chen Z. Artificial intelligence in echocardiography: detection, functional evaluation, and disease diagnosis. *Cardiovasc Ultrasound*. 2021;19(1):29.[[10.1186/s12947-021-00261-2](https://doi.org/10.1186/s12947-021-00261-2)][[PMID](https://pubmed.ncbi.nlm.nih.gov/34444444/)]
- [7]Tran KA, Kondrashova O, Bradley A, Williams ED, Pearson JV, Waddell N. Deep learning in cancer diagnosis, prognosis and treatment selection. *Genome Med*. 2021;13(1):152.[[10.1186/s13073-021-00968-x](https://doi.org/10.1186/s13073-021-00968-x)][[PMID](https://pubmed.ncbi.nlm.nih.gov/34444444/)]
- [8]Reddy KVV, Elamvazuthi I, Abd Aziz A, Paramasivam S, Chua HN, Pranavanand S, editors. Rotation forest ensemble classifier to improve the cardiovascular disease risk prediction accuracy. 2021 8th NAFOSTED Conference on Information and Computer Science (NICS); 2021: IEEE. [[10.1109/NICSS54270.2021.9701455](https://doi.org/10.1109/NICSS54270.2021.9701455)]
- [9]Gurupur VP, Kulkarni SA, Liu X, Desai U, Nasir AJJoE, Intelligence TA. Analysing the power of deep learning techniques over the traditional methods using medicare utilisation and provider data. 2018;31:115 - 99[[10.1080/0952813X.2018.1518999](https://doi.org/10.1080/0952813X.2018.1518999)]
- [10]Ojha AKJJoAI, Machine Learning, Network N. AI-Augmented Fault Detection and Diagnosis in VLSI Circuits: A Step toward Intelligent Chip Design. 2024[[10.55529/jaimInn.46.39.46](https://doi.org/10.55529/jaimInn.46.39.46)]
- [11]Goshayeshi L, Hoseini B, Yousefi Z, Khoie A, Etmnani K, Esmailzadeh A, et al. Predictive model for survival in patients with gastric cancer. *Electron Physician*. 2017;9(12):6035-42.[[10.19082/6035](https://doi.org/10.19082/6035)] [[PMID](https://pubmed.ncbi.nlm.nih.gov/31111111/)]
- [12]Sabietan G, Azimi A, Kazemi A, Hoseini B, Asmarian N, Khaloo V, et al. Prediction of Patients with COVID-19 Requiring Intensive Care: A Cross-sectional Study Based on Machine-learning Approach from Iran. *Indian J Crit Care Med*. 2022;26(6):688-95.[[10.5005/jp-journals-10071-24226](https://doi.org/10.5005/jp-journals-10071-24226)] [[PMID](https://pubmed.ncbi.nlm.nih.gov/36666666/)]
- [13]Tolstyak Y, Zhuk R, Yakovlev I, Shakhovska N, Gregus ml M, Chopyak V, et al. The ensembles of machine learning methods for survival predicting after kidney transplantation. 2021;11(21):10380[[10.3390/app112110380](https://doi.org/10.3390/app112110380)]
- [14]Saber-Karimian M, Khorasanchi Z, Ghazizadeh H, Tayefi M, Saffar S, Ferns GA, et al. Potential value and impact of data mining and machine learning in clinical diagnostics. *Crit Rev Clin Lab Sci*. 2021;58(4):275-96.[[10.1080/10408363.2020.1857681](https://doi.org/10.1080/10408363.2020.1857681)] [[PMID](https://pubmed.ncbi.nlm.nih.gov/34444444/)]
- [15]Cao LL, Peng M, Xie X, Chen GQ, Huang SY, Wang JY, et al. Artificial intelligence in liver ultrasound. *World J Gastroenterol*. 2022;28(27):3398-409.[[10.3748/wjg.v28.i27.3398](https://doi.org/10.3748/wjg.v28.i27.3398)] [[PMID](https://pubmed.ncbi.nlm.nih.gov/36666666/)]
- [16] Lu F, Meng Y, Song X, Li X, Liu Z, Gu C, et al. Artificial Intelligence in Liver Diseases: Recent Advances. *Adv Ther*. 2024;41(3):967-90.[[10.1007/s12325-024-02781-5](https://doi.org/10.1007/s12325-024-02781-5)] [[PMID](https://pubmed.ncbi.nlm.nih.gov/36666666/)]
- [17]Nishida N, Kudo M. Artificial intelligence models for the diagnosis and management of liver diseases. *Ultrasonography*. 2023;42(1):10-9.[[10.14366/usg.22110](https://doi.org/10.14366/usg.22110)]
- [18]Mahzari AJELJ. Artificial intelligence in nonalcoholic fatty liver disease. 2022;12(1):69[[10.1186/s43066-022-00224-w](https://doi.org/10.1186/s43066-022-00224-w)]
- [19]Alqahtani SA, Schattenberg JM. Nonalcoholic fatty liver disease: use of diagnostic biomarkers and modalities in clinical practice. *Expert Rev Mol Diagn*. 2021;21(10):1065-78.[[10.1080/14737159.2021.1964958](https://doi.org/10.1080/14737159.2021.1964958)] [[PMID](https://pubmed.ncbi.nlm.nih.gov/34444444/)]
- [20] Bharti P, Mittal D, Ananthasivan R. Computer-aided Characterization and Diagnosis of Diffuse Liver Diseases Based on Ultrasound Imaging: A Review. *Ultrason Imaging*. 2017;39(1):33-61.[[10.1177/0161734616639875](https://doi.org/10.1177/0161734616639875)] [[PMID](https://pubmed.ncbi.nlm.nih.gov/34444444/)]
- [21] Grissa D, Nytoft Rasmussen D, Krag A, Brunak S, Juhl Jensen L. Alcoholic liver disease: A registry view on comorbidities and disease prediction. *PLoS Computational Biology*. 2020 Sep 22;16(9):e1008244. [[10.1371/journal.pcbi.1008244](https://doi.org/10.1371/journal.pcbi.1008244)] [[PMID](https://pubmed.ncbi.nlm.nih.gov/32888888/)]
- [22] Kim T, Lee DH, Park EK, Choi S. Deep learning techniques for fatty liver using multi-view ultrasound images scanned by different scanners: Development and validation study. *JMIR Medical Informatics*. 2021 Nov 18;9(11):e30066. [[10.2196/30066](https://doi.org/10.2196/30066)] [[PMID](https://pubmed.ncbi.nlm.nih.gov/34444444/)]
- [23] Yang Y, Liu J, Sun C, Shi Y, Hsing JC, Kama A, Keller CA, Antil N, Rubin D, Wang H, Ying H. Nonalcoholic fatty liver disease (NAFLD) detection and deep learning in a Chinese community-based population. *European Radiology*. 2023 Aug;33(8):5894-906. [[10.1007/s00330-023-09515-1](https://doi.org/10.1007/s00330-023-09515-1)] [[PMID](https://pubmed.ncbi.nlm.nih.gov/36666666/)]
- [24] Zhang D, Zhang XY, Duan YY, Dietrich CF, Cui XW, Zhang CX. An overview of ultrasound-derived radiomics and deep learning in liver. *Medical Ultrasonography*. 2023 Dec 27;25(4):445-52. [[10.11152/mu-4080](https://doi.org/10.11152/mu-4080)] [[PMID](https://pubmed.ncbi.nlm.nih.gov/36666666/)]
- [25] Sowa J-P, Heider D, Bechmann LP, Gerken G, Hoffmann D, Canbay AJPo. Novel algorithm for non-invasive assessment of fibrosis in NAFLD. 2013;8(4):e62439. [[10.1371/journal.pone.0062439](https://doi.org/10.1371/journal.pone.0062439)] [[PMID](https://pubmed.ncbi.nlm.nih.gov/34444444/)]

- [26] Yang A, Zhu X, Zhang L, Zhang Y, Zhang D, Jin M, et al. Non-invasive evaluation of NAFLD and the contribution of genes: an MRI-PDFF-based cross-sectional study. 2022;16(5):1035-51. [[10.1007/s12072-022-10355-2](#)] [PMID]
- [27] Zhang L, Huang Y, Huang M, Zhao CH, Zhang YJ, Wang Y. Development of cost-effective fatty liver disease prediction models in a chinese population: statistical and machine learning approaches. JMIR Formative Research. 2024 Feb 16;8:e53654. [[10.2196/53654](#)] [PMID]
- [28] Makkena KR, Natarajan K. Classification algorithms for liver epidemic identification. EAI Endorsed Trans. Perv. Health Tech. 2023;9:1-3.
- [29] Owjimehr M, Danyali H, Helfroush MSJJoMS, Sensors. An improved method for liver diseases detection by ultrasound image analysis. 2015;5(1):21-9. [PMID]
- [30] Wu CT, Chu TW, Jang JS. Current-Visit and Next-Visit Prediction for Fatty Liver Disease With a Large-Scale Dataset: Model Development and Performance Comparison. JMIR Medical Informatics. 2021 Aug 12;9(8):e26398. [[10.2196/26398](#)] [PMID]
- [31] Feng G, Zheng KI, Li YY, Rios RS, Zhu PW, Pan XY, Li G, Ma HL, Tang LJ, Byrne CD, Targher G. Machine learning algorithm outperforms fibrosis markers in predicting significant fibrosis in biopsy-confirmed NAFLD. Journal of Hepato-Biliary-Pancreatic Sciences. 2021 Jul;28(7):593-603. [[10.1002/jhbp.972](#)] [PMID]
- [32] Nagy G, Munteanu M, Gordan M, Chira R, Iancu M, Crisan D, Mircea PA. Computerized ultrasound image analysis for noninvasive evaluation of hepatic steatosis. Medical ultrasonography. 2015 Dec 1;17(4):431-6. [[10.11152/mu.2013.2066.174.cmu](#)] [PMID]
- [33] Zhu Q, Li H, Ao Z, Xu H, Luo J, Kaurich C, Yang R, Zhu PW, Chen SD, Wang XD, Tang LJ. Lipidomic identification of urinary extracellular vesicles for non-alcoholic steatohepatitis diagnosis. Journal of Nanobiotechnology. 2022 Jul 27;20(1):349. [[10.1186/s12951-022-01540-4](#)] [PMID]
- [34] Li G, Zheng TL, Chi XL, Zhu YF, Chen JJ, Xu L, Shi JP, Wang XD, Zhao WG, Byrne CD, Targher G. LEARN algorithm: a novel option for predicting non-alcoholic steatohepatitis. Hepatobiliary Surgery and Nutrition. 2023 Mar 30;12(4):507. [[10.21037/hbsn-21-523](#)] [PMID]
- [35] Yang T, Zhao B, Pei DJD, Metabolic Syndrome, Obesity. Estimation of the prevalence of nonalcoholic fatty liver disease in an adult population in Northern China using the data mining approach. 2021:3437-45. [[10.2147/DMSO.S320808](#)] [PMID]
- [36] Wang RR, Chen JL, Duan SJ, Lu YX, Chen P, Zhou YC, Yao SK. Noninvasive Diagnostic Technique for Nonalcoholic Fatty Liver Disease Based on Features of Tongue Images. Chinese journal of integrative medicine. 2024 Mar;30(3):203-12. [[10.1007/s11655-023-3616-1](#)] [PMID]
- [37] Chae W, Lee KJ, Huh KY, Moon JS, Ko JS, Cho JY. Association of Metabolic Signatures with Nonalcoholic Fatty Liver Disease in Pediatric Population. Metabolites. 2022 Sep 19;12(9):881. [[10.3390/metabo12090881](#)] [PMID]
- [38] Docherty M, Regnier SA, Capkun G, Balp MM, Ye Q, Janssens N, Tietz A, Löffler J, Cai J, Pedrosa MC, Schattenberg JM. Development of a novel machine learning model to predict presence of nonalcoholic steatohepatitis. Journal of the American Medical Informatics Association. 2021 Jun 1;28(6):1235-41. [[10.1093/jamia/ocab003](#)] [PMID]
- [39] Arzehgar A, Nezhad Noor Nia RG, Dehdeleh V, Roudi F, Eslami S. Non-Alcoholic Fatty Liver Disease Diagnosis with Multi-Group Factors. InHealthcare Transformation with Informatics and Artificial Intelligence 2023 (pp. 503-506). IOS Press. [[10.3233/SHTI230543](#)] [PMID]
- [40] Ma X, Yang C, Liang K, Sun B, Jin W, Chen L, Dong M, Liu S, Xin Y, Zhuang L. A predictive model for the diagnosis of non-alcoholic fatty liver disease based on an integrated machine learning method. American Journal of Translational Research. 2021 Nov 15;13(11):12704. [PMID]
- [41] Das A, Connell M, Khetarpal S. Digital image analysis of ultrasound images using machine learning to diagnose pediatric nonalcoholic fatty liver disease. Clinical imaging. 2021 Sep 1;77:62-8. [[10.1016/j.clinimag.2021.02.038](#)] [PMID]
- [42] Shahabi M, Hassanpour H, Mashayekhi H. Rule extraction for fatty liver detection using neural networks. Neural Computing and Applications. 2019 Apr 1;31:979-89.
- [43] Jiang T, Guo XJ, Tu LP, Lu Z, Cui J, Ma XX, Hu XJ, Yao XH, Cui LT, Li YZ, Huang JB. Application of computer tongue image analysis technology in the diagnosis of NAFLD. Computers in Biology and Medicine. 2021 Aug 1;135:104622. [[10.1016/j.compbimed.2021.104622](#)] [PMID]
- [44] Jeon SK, Lee JM, Joo I, Yoon JH, Lee G. Two-dimensional convolutional neural network using quantitative US for noninvasive assessment of hepatic steatosis in NAFLD. Radiology. 2023 Jan 3;307(1):e221510. [[10.1148/radiol.221510](#)] [PMID]
- [45] Ghandian S, Thapa R, Garikipati A, Barnes G, Green-Saxena A, Calvert J, Mao Q, Das R. Machine learning to predict progression of non-alcoholic fatty liver to non-alcoholic steatohepatitis or fibrosis. JGH Open. 2022 Mar;6(3):196-204. [[10.1002/jgh3.12716](#)] [PMID]
- [46] McTeer M, Applegate D, Mesenbrink P, Ratziu V, Schattenberg JM, Bugianesi E, Geier A, Romero Gomez M, Dufour JF, Ekstedt M, Francque S. Machine learning approaches to enhance diagnosis and staging of patients with MASLD using routinely available clinical information. Plos one. 2024 Feb 29;19(2):e0299487. [[10.1371/journal.pone.0299487](#)] [PMID]
- [47] Han N, He J, Shi L, Zhang M, Zheng J, Fan Y. Identification of biomarkers in nonalcoholic fatty liver disease: a machine learning method and experimental study. Frontiers in Genetics. 2022 Nov 7;13:1020899. [[10.3389/fgene.2022.1020899](#)] [PMID]
- [48] Douali N. Nonalcoholic Steatohepatitis Diagnosis—A Model-Related Personalized Medicine Approach. InpHealth 2022 2022 (pp. 191-195). IOS Press. [[10.3233/SHTI220982](#)] [PMID]
- [49] Cheung JT, Zhang X, Wong GL, Yip TC, Lin H, Li G, Leung HH, Lai JC, Mahadeva S, Nik Mustapha NR, Wang XD. MAFLD fibrosis score: using routine measures to identify advanced fibrosis in metabolic-associated fatty liver disease. Alimentary Pharmacology & Therapeutics. 2023 Dec;58(11-12):1194-204. [[10.1111/apt.17722](#)] [PMID]
- [50] Verma N, Duseja A, Mehta M, De A, Lin H, Wong VW, Wong GL, Rajaram RB, Chan WK, Mahadeva S, Zheng MH. Machine learning improves the prediction of significant fibrosis in Asian patients with metabolic dysfunction-associated steatotic liver

- disease—The Gut and Obesity in Asia (GO-ASIA) Study. *Alimentary Pharmacology & Therapeutics*. 2024 Mar;59(6):774-88. [[10.1111/apt.17891](#)] [PMID]
- [51] Su TH, Wu CH, Kao JH. Artificial intelligence in precision medicine in hepatology. *Journal of Gastroenterology and Hepatology*. 2021 Mar;36(3):569-80. [[10.1111/jgh.15415](#)] [PMID]
- [52] Subramanya MB, Kumar V, Mukherjee S, Saini M. A CAD system for B-mode fatty liver ultrasound images using texture features. *Journal of medical engineering & technology*. 2015 Feb 17;39(2):123-30. [[10.3109/03091902.2014.990160](#)] [PMID]
- [53] Alici-Karaca D, Akay B, Yay A, Suna P, Nalbantoglu OU, Karaboga D, Basturk A, Balcioglu E, Baran M. A new lightweight convolutional neural network for radiation-induced liver disease classification. *Biomedical Signal Processing and Control*. 2022 Mar 1;73:103463.
- [54] Pei X, Deng Q, Liu Z, Yan X, Sun WJAoN, Metabolism. Machine learning algorithms for predicting fatty liver disease. 2021;77(1):38-45. [[10.1159/000513654](#)] [PMID]
- [55] Chiappini F, Coilly A, Kadar H, Gual P, Tran A, Desterke C, Samuel D, Duclos-Vallée JC, Touboul D, Bertrand-Michel J, Brunelle A. Metabolism dysregulation induces a specific lipid signature of nonalcoholic steatohepatitis in patients. *Scientific reports*. 2017 Apr 24;7(1):46658. [[10.1038/srep46658](#)] [PMID]
- [56] Jiang T, Lu Z, Hu X, Zeng L, Ma X, Huang J, Cui J, Tu L, Zhou C, Yao X, Xu J. Deep learning multi-label tongue image analysis and its application in a population undergoing routine medical checkup. *Evidence-Based Complementary and Alternative Medicine*. 2022;2022(1):3384209. [[10.1155/2022/3384209](#)] [PMID]
- [57] Zamanian H, Shalhaf A. Estimation of non-alcoholic steatohepatitis (NASH) disease using clinical information based on the optimal combination of intelligent algorithms for feature selection and classification. *Computer Methods in Biomechanics and Biomedical Engineering*. 2024 Jun 10;27(8):964-79. [[10.1080/10255842.2023.2217978](#)] [PMID]
- [58] Douali N, Abdennour M, Sasso M, Miette V, Tordjman J, Bedossa P, Veyrie N, Poitou C, Aron-Wisniewsky J, Clément K, Jaulent MC. Noninvasive diagnosis of nonalcoholic steatohepatitis disease based on clinical decision support system. In *MEDINFO 2013* 2013 (pp. 1178-1178). IOS Press. [PMID]
- [59] Minhas FU, Sabih D, Hussain M. Automated classification of liver disorders using ultrasound images. *Journal of medical systems*. 2012 Oct;36:3163-72. [[10.1007/s10916-011-9803-1](#)] [PMID]
- [60] Wagner J, Kumar Y, Lautenbach A, von Kroge P, Wolter S, Mann O, Izbicki J, Gagliani N, Duprée A. Fatty acid-binding protein-4 (FABP4) and matrix metalloproteinase-9 (MMP9) as predictive values for nonalcoholic steatohepatitis (NASH). *Lipids in Health and Disease*. 2023 Jan 6;22(1):1. [[10.1186/s12944-022-01764-1](#)] [PMID]
- [61] Gaber A, Youness HA, Hamdy A, Abdelaal HM, Hassan AM. Automatic classification of fatty liver disease based on supervised learning and genetic algorithm. *Applied Sciences*. 2022 Jan 5;12(1):521.
- [62] Lusnig L, Sagingalieva A, Surmach M, Protasevich T, Michiu O, McLoughlin J, Mansell C, de'Petris G, Bonazza D, Zanconati F, Melnikov A. Hybrid quantum image classification and federated learning for hepatic steatosis diagnosis. *Diagnostics*. 2024 Mar 6;14(5):558. [[10.3390/diagnostics14050558](#)] [PMID]
- [63] Zhao M, Song C, Luo T, Huang T, Lin S. Fatty liver disease prediction model based on big data of electronic physical examination records. *Frontiers in public health*. 2021 Apr 12;9:668351. [[10.3389/fpubh.2021.668351](#)] [PMID]
- [64] Ülger Y, Delik A. Artificial intelligence model with deep learning in nonalcoholic fatty liver disease diagnosis: Genetic based artificial neural networks. *Nucleosides, Nucleotides & Nucleic Acids*. 2023 May 4;42(5):398-406. [[10.1080/15257770.2022.2152046](#)] [PMID]
- [65] Sorino P, Campanella A, Bonfiglio C, Mirizzi A, Franco I, Bianco A, Caruso MG, Misciagna G, Aballay LR, Buongiorno C, Liuzzi R. Development and validation of a neural network for NAFLD diagnosis. *Scientific Reports*. 2021 Oct 12;11(1):20240. [[10.1038/s41598-021-99400-y](#)] [PMID]
- [66] Xiao W, Huang X, Wang JH, Lin DR, Zhu Y, Chen C, Yang YH, Xiao J, Zhao LQ, Li JP, Cheung CY. Screening and identifying hepatobiliary diseases through deep learning using ocular images: a prospective, multicentre study. *The Lancet Digital Health*. 2021 Feb 1;3(2):e88-97. [[10.1016/S2589-7500\(20\)30288-0](#)] [PMID]
- [67] Sripongpun P, Kim WR, Mannalithara A, Charu V, Vidovszky A, Asch S, Desai M, Kim SH, Kwong AJ. The steatosis-associated fibrosis estimator (SAFE) score: a tool to detect low-risk NAFLD in primary care. *Hepatology*. 2023 Jan 1;77(1):256-67. [[10.1002/hep.32545](#)] [PMID]
- [68] Wang Q, Lai MW, Bin G, Ding Q, Wu S, Zhou Z, Tsui PH. MBR-Net: A multi-branch residual network based on ultrasound backscattered signals for characterizing pediatric hepatic steatosis. *Ultrasonics*. 2023 Dec 1;135:107093. [[10.1016/j.ultras.2023.107093](#)] [PMID]
- [69] Huang H, Liu Y, Xiong Q, Xing Y, Du H. A fatty liver diseases classification network based on adaptive coordination attention with label smoothing. *Biomedical Signal Processing and Control*. 2023 Sep 1;86:105267.
- [70] Guarneros-Nolasco LR, Alor-Hernández G, Prieto-Avalos G, Sánchez-Cervantes JL. Early identification of risk factors in non-alcoholic fatty liver disease (NAFLD) using machine learning. *Mathematics*. 2023 Jul 7;11(13):3026.
- [71] Suárez M, Martínez R, Torres AM, Torres B, Mateo J. A Machine Learning Method to Identify the Risk Factors for Liver Fibrosis Progression in Nonalcoholic Steatohepatitis. *Digestive Diseases and Sciences*. 2023 Sep;68(9):3801-9. [[10.1007/s10620-023-08031-y](#)] [PMID]
- [72] Gheorghe EC, Nicolau C, Kamal A, Udristoiu A, Gruionu L, Saftoiu A. Artificial Intelligence (AI)-Enhanced Ultrasound Techniques Used in Non-Alcoholic Fatty Liver Disease: Are They Ready for Prime Time?. *Applied Sciences*. 2023 Apr 19;13(8):5080.
- [73] Acharya UR, Fujita H, Sudarshan VK, Mookiah MR, Koh JE, Tan JH, Hagiwara Y, Chua CK, Junnarkar SP, Vijayanathan A, Ng KH. An integrated index for identification of fatty liver disease using radon transform and discrete cosine transform features in ultrasound images. *Information Fusion*. 2016 Sep 1;31:43-53.
- [74] Zhu Y, Zhang H, Jiang P, Xie C, Luo Y, Chen J. Transcriptional and epigenetic alterations in the progression of non-alcoholic fatty

- liver disease and biomarkers helping to diagnose non-alcoholic steatohepatitis. *Biomedicines*. 2023 Mar 21;11(3):970. [[10.3390/biomedicines11030970](https://doi.org/10.3390/biomedicines11030970)] [PMID]
- [75] Naderi Yaghoti, Amir Reza, Shalhaf, Maghsoudi. Automatic classification of liver fat using tissue features from ultrasound images. *Journal of the Faculty of Medicine, Tehran University of Medical Sciences*. 2021 Apr 10;79(1):10-7.
- [76] Ma H, Xu CF, Shen Z, Yu CH, Li YM. Application of machine learning techniques for clinical predictive modeling: a cross-sectional study on nonalcoholic fatty liver disease in China. *BioMed research international*. 2018;2018(1):4304376. [[10.1155/2018/4304376](https://doi.org/10.1155/2018/4304376)] [PMID]
- [77] Acharya UR, Fujita H, Bhat S, Raghavendra U, Gudigar A, Molinari F, Vijayanathan A, Ng KH. Decision support system for fatty liver disease using GIST descriptors extracted from ultrasound images. *Information Fusion*. 2016 May 1;29:32-9.
- [78] Birjandi M, Ayatollahi SM, Pourahmad S, Safarpour AR. Prediction and diagnosis of non-alcoholic fatty liver disease (NAFLD) and identification of its associated factors using the classification tree method. *Iranian Red Crescent Medical Journal*. 2016 Aug 9;18(11):e32858. [[10.5812/ircmj.32858](https://doi.org/10.5812/ircmj.32858)] [PMID]
- [79] Wu Y, Yang X, Morris HL, Gurka MJ, Shenkman EA, Cusi K, Bril F, Donahoo WT. Noninvasive diagnosis of nonalcoholic steatohepatitis and advanced liver fibrosis using machine learning methods: Comparative study with existing quantitative risk scores. *JMIR Medical Informatics*. 2022 Jun 6;10(6):e36997. [[10.2196/36997](https://doi.org/10.2196/36997)] [PMID]
- [80] Nanyue W, Youhua Y, Dawei H, Bin X, Jia L, Tongda L, Liyuan X, Zengyu S, Yanping C, Jia W. Pulse diagnosis signals analysis of fatty liver disease and cirrhosis patients by using machine learning. *The Scientific World Journal*. 2015;2015(1):859192. [[10.1155/2015/859192](https://doi.org/10.1155/2015/859192)] [PMID]
- [81] Chen YS, Chen D, Shen C, Chen M, Jin CH, Xu CF, Yu CH, Li YM. A novel model for predicting fatty liver disease by means of an artificial neural network. *Gastroenterology report*. 2021 Jan 1;9(1):31-7. [[10.1093/gastro/goaa035](https://doi.org/10.1093/gastro/goaa035)] [PMID]
- [82] Rajathi GI, Jiji GW. Chronic liver disease classification using hybrid whale optimization with simulated annealing and ensemble classifier. *Symmetry*. 2019 Jan 2;11(1):33.
- [83] Razmpour F, Daryabeygi-Khotbehsara R, Soleimani D, Asgharnezhad H, Shamsi A, Bajestani GS, Nematy M, Pour MR, Maddison R, Islam SM. Application of machine learning in predicting non-alcoholic fatty liver disease using anthropometric and body composition indices. *Scientific reports*. 2023 Mar 27;13(1):4942. [[10.1038/s41598-023-32129-y](https://doi.org/10.1038/s41598-023-32129-y)] [PMID]
- [84] Vandel J, Dubois-Chevalier J, Gheeraert C, Derudas B, Raverdy V, Thuillier D, Gaal L, Francque S, Pattou F, Staels B, Eeckhoutte J. Hepatic molecular signatures highlight the sexual dimorphism of nonalcoholic steatohepatitis (NASH). *Hepatology*. 2021 Mar;73(3):920-36. [[10.1002/hep.31312](https://doi.org/10.1002/hep.31312)] [PMID]
- [85] Guo X, Wang F, Teodoro G, Farris AB, Kong J. Liver steatosis segmentation with deep learning methods. In 2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI 2019) 2019 Apr 8 (pp. 24-27). IEEE. [[10.1109/isbi.2019.8759600](https://doi.org/10.1109/isbi.2019.8759600)] [PMID]
- [86] Kalyan K, Jakhia B, Lele RD, Joshi M, Chowdhary A. Artificial neural network application in the diagnosis of disease conditions with liver ultrasound images. *Advances in bioinformatics*. 2014;2014(1):708279. [[10.1155/2014/708279](https://doi.org/10.1155/2014/708279)] [PMID]
- [87] Yasar O, Long P, Harder B, Marshall H, Bhasin S, Lee S, Delegge M, Roy S, Doyle O, Leavitt N, Rigg J. Machine learning using longitudinal prescription and medical claims for the detection of non-alcoholic steatohepatitis (NASH). *BMJ Health & Care Informatics*. 2022 Mar 30;29(1):e100510. [[10.1136/bmjhci-2021-100510](https://doi.org/10.1136/bmjhci-2021-100510)] [PMID]
- [88] Acharya UR, Sree SV, Ribeiro R, Krishnamurthi G, Marinho RT, Sanches J, Suri JS. Data mining framework for fatty liver disease classification in ultrasound: a hybrid feature extraction paradigm. *Medical physics*. 2012 Jul;39(7Part1):4255-64. [[10.1118/1.4725759](https://doi.org/10.1118/1.4725759)] [PMID]
- [89] Perakakis N, Polyzos SA, Yazdani A, Sala-Vila A, Kountouras J, Anastasilakis AD, Mantzoros CS. Non-invasive diagnosis of non-alcoholic steatohepatitis and fibrosis with the use of omics and supervised learning: a proof of concept study. *Metabolism*. 2019 Dec 1;101:154005. [[10.1016/j.metabol.2019.154005](https://doi.org/10.1016/j.metabol.2019.154005)] [PMID]
- [90] Mihailescu DM, Gui V, Toma CI, Popescu A, Sporea I. Computer aided diagnosis method for steatosis rating in ultrasound images using random forests. *Medical Ultrasonography*. 2013 Sep 1;15(3):184-90. [[10.11152/mu.2013.2066.153.dmm1vg2](https://doi.org/10.11152/mu.2013.2066.153.dmm1vg2)] [PMID]
- [91] Wang L, He W, Wang X, Wang J, Wei X, Wu D, Wu Y. Potential diagnostic markers shared between non-alcoholic fatty liver disease and atherosclerosis determined by machine learning and bioinformatic analysis. *Frontiers in Medicine*. 2024 Mar 28;11:1322102. [[10.3389/fmed.2024.1322102](https://doi.org/10.3389/fmed.2024.1322102)] [PMID]
- [92] Atabaki-Pasdar N, Ohlsson M, Viñuela A, Frau F, Pomares-Millan H, Haid M, Jones AG, Thomas EL, Koivula RW, Kurbasic A, Mutie PM. Predicting and elucidating the etiology of fatty liver disease: A machine learning modeling and validation study in the IMI DIRECT cohorts. *PLoS medicine*. 2020 Jun 19;17(6):e1003149. [[10.1371/journal.pmed.1003149](https://doi.org/10.1371/journal.pmed.1003149)] [PMID]
- [93] Qin S, Hou X, Wen Y, Wang C, Tan X, Tian H, Ao Q, Li J, Chu S. Machine learning classifiers for screening nonalcoholic fatty liver disease in general adults. *Scientific Reports*. 2023 Mar 3;13(1):3638. [[10.1038/s41598-023-30750-5](https://doi.org/10.1038/s41598-023-30750-5)] [PMID]
- [94] Yip TF, Ma AJ, Wong VS, Tse YK, Chan HY, Yuen PC, Wong GH. Laboratory parameter-based machine learning model for excluding non-alcoholic fatty liver disease (NAFLD) in the general population. *Alimentary pharmacology & therapeutics*. 2017 Aug;46(4):447-56. [[10.1111/apt.14172](https://doi.org/10.1111/apt.14172)] [PMID]
- [95] Canbay A, Kälsch J, Neumann U, Rau M, Hohenester S, Baba HA, Rust C, Geier A, Heider D, Sowa JP. Non-invasive assessment of NAFLD as systemic disease—a machine learning perspective. *PLoS one*. 2019 Mar 26;14(3):e0214436. [[10.1371/journal.pone.0214436](https://doi.org/10.1371/journal.pone.0214436)] [PMID]
- [96] Cheng CT, Cai J, Teng W, Zheng Y, Huang YT, Wang YC, Peng CW, Tang Y, Lee WC, Yeh TS, Xiao J. A flexible three-dimensional heterophase computed tomography hepatocellular carcinoma detection algorithm for generalizable and practical screening. *Hepatology Communications*. 2022 Oct;6(10):2901-13. [[10.1002/hep4.2029](https://doi.org/10.1002/hep4.2029)] [PMID]

- [97] Zhang P, Huang H, Xiong Q, He X, Liu Y. Feature analysis and automatic classification of B-mode ultrasound images of fatty liver. *Biomedical Signal Processing and Control*. 2023 Jan 1;79:104073.
- [98] Zhang D, Zhang X, Lan Y, Wang G. Fatty Liver Recognition Based on Computer Vision. *Journal of Applied Sciences*. 2013 Dec;13(14):2730-4.
- [99] Wen H, Zheng W, Li M, Li Q, Liu Q, Zhou J, Liu Z, Chen X. Multiparametric quantitative US examination of liver fibrosis: a feature-engineering and machine-learning based analysis. *IEEE Journal of Biomedical and Health Informatics*. 2021 Jul 30;26(2):715-26. [[10.1109/JBHI.2021.3100319](#)] [[PMID](#)]
- [100] Goldman O, Ben-Assuli O, Rogowski O, Zeltser D, Shapira I, Berliner S, Zelber-Sagi S, Shenhar-Tsarfaty S. Non-alcoholic fatty liver and liver fibrosis predictive analytics: risk prediction and machine learning techniques for improved preventive medicine. *Journal of Medical Systems*. 2021 Feb;45:1-2.
- [101] [[10.1007/s10916-020-01693-5](#)] [[PMID](#)] Pournik O, Dorri S, Zabolinezhad H, Alavian SM, Eslami S. A diagnostic model for cirrhosis in patients with non-alcoholic fatty liver disease: an artificial neural network approach. *Medical journal of the Islamic Republic of Iran*. 2014 Oct 21;28:116. [[PMID](#)]
- [102] Karagoz MA, Akay B, Basturk A, Karaboga D, Nalbantoglu OJNC, Applications. An unsupervised transfer learning model based on convolutional auto encoder for non-alcoholic steatohepatitis activity scoring and fibrosis staging of liver histopathological images. 2023;35(14):10605-19.
- [103] Suárez M, Martínez R, Torres AM, Ramón A, Blasco P, Mateo J. Personalized risk assessment of hepatic fibrosis after cholecystectomy in metabolic-associated steatotic liver disease: a machine learning approach. *Journal of Clinical Medicine*. 2023 Oct 12;12(20):6489. [[10.3390/jcm12206489](#)] [[PMID](#)]
- [104] Dai L, Yuan W, Jiang R, Zhan Z, Zhang L, Xu X, Qian Y, Yang W, Zhang Z. Machine learning-based integration identifies the ferroptosis hub genes in nonalcoholic steatohepatitis. *Lipids in Health and Disease*. 2024 Jan 23;23(1):23. [[10.1186/s12944-023-01988-9](#)] [[PMID](#)]
- [105] Tahmasebi A, Wang S, Wessner CE, Vu T, Liu JB, Forsberg F, Civan J, Guglielmo FF, Eisenbrey JR. Ultrasound-based machine learning approach for detection of nonalcoholic fatty liver disease. *Journal of Ultrasound in Medicine*. 2023 Aug;42(8):1747-56. [[10.1002/jum.16194](#)] [[PMID](#)]
- [106] Perveen S, Shahbaz M, Keshavjee K, Guergachi A. A systematic machine learning based approach for the diagnosis of non-alcoholic fatty liver disease risk and progression. *Scientific reports*. 2018 Feb 1;8(1):2112. [[10.1038/s41598-018-20166-x](#)] [[PMID](#)]
- [107] Liu Q, Liu Z, Xu W, Wen H, Dai M, Chen X. Diagnosis of significant liver fibrosis by using a DCNN model with fusion of features from US B-mode image and Nakagami parametric map: an animal study. *IEEE Access*. 2021 Mar 9;9:89300-10.
- [108] Qu HQ, Li Q, Grove ML, Lu Y, Pan JJ, Rentfro AR, Bickel PE, Fallon MB, Hanis CL, Boerwinkle E, McCormick JB. Population-based risk factors for elevated alanine aminotransferase in a South Texas Mexican-American population. *Archives of medical research*. 2012 Aug 1;43(6):482-8. [[10.1016/j.arcmed.2012.08.005](#)] [[PMID](#)]
- [109] Chou TH, Yeh HJ, Chang CC, Tang JH, Kao WY, Su IC, Li CH, Chang WH, Huang CK, Sufriyana H, Su EC. Deep learning for abdominal ultrasound: A computer-aided diagnostic system for the severity of fatty liver. *Journal of the Chinese Medical Association*. 2021 Sep 1;84(9):842-50. [[10.1097/JCMA.0000000000000585](#)] [[PMID](#)]
- [110] Li J, Yang D, Chen T, Li T, Jiang P, Zheng X, Jiang F. Nine Markers to Predict Nonalcoholic Fatty Liver Disease for a Chinese Diabetic Population. *Journal of Medical Imaging and Health Informatics*. 2021 Mar 1;11(3):730-5.
- [111] Podder S, Mallick A, Das S, Sau K, Roy A. Accurate diagnosis of liver diseases through the application of deep convolutional neural network on biopsy images. *AIMS Biophysics*. 2023 Oct 1;10(4).
- [112] Rhyou SY, Yoo JC. Cascaded deep learning neural network for automated liver steatosis diagnosis using ultrasound images. *Sensors*. 2021 Aug 5;21(16):5304. [[10.3390/s21165304](#)] [[PMID](#)]
- [113] Wang C, Yan J, Zhang S, Xie Y, Nie Y, Chen Z, Xu S. Screening new blood indicators for Non-alcoholic Fatty Liver Disease (NAFLD) diagnosis of Chinese based on machine learning. *Frontiers in Medicine*. 2022 Jun 9;9:771219. [[10.3389/fmed.2022.771219](#)] [[PMID](#)]
- [114] Chen YY, Lin CY, Yen HH, Su PY, Zeng YH, Huang SP, Liu IL. Machine-learning algorithm for predicting fatty liver disease in a Taiwanese population. *Journal of Personalized Medicine*. 2022 Jun 23;12(7):1026. [[10.3390/jpm12071026](#)] [[PMID](#)]
- [115] Byra M, Styczynski G, Szmigielski C, Kalinowski P, Michałowski Ł, Paluszkievicz R, Ziarkiewicz-Wróblewska B, Zieniewicz K, Sobieraj P, Nowicki A. Transfer learning with deep convolutional neural network for liver steatosis assessment in ultrasound images. *International journal of computer assisted radiology and surgery*. 2018 Dec;13:1895-903. [[10.1007/s11548-018-1843-2](#)] [[PMID](#)]
- [116] Mamandipoor B, Wernly S, Semmler G, Flamm M, Jung C, Aigner E, Datz C, Wernly B, Osmani V. Machine learning models predict liver steatosis but not liver fibrosis in a prospective cohort study. *Clinics and research in hepatology and gastroenterology*. 2023 Aug 1;47(7):102181. [[10.1016/j.clinre.2023.102181](#)] [[PMID](#)]
- [117] Renukadevi T, Karunakaran S. Optimizing deep belief network parameters using grasshopper algorithm for liver disease classification. *International Journal of Imaging Systems and Technology*. 2020 Mar;30(1):168-84.
- [118] Flores YN, Amoon AT, Su B, Velazquez-Cruz R, Ramírez-Palacios P, Salmerón J, Rivera-Paredes B, Sinsheimer JS, Lusia AJ, Huertas-Vazquez A, Saab S. Serum lipids are associated with nonalcoholic fatty liver disease: a pilot case-control study in Mexico. *Lipids in health and disease*. 2021 Dec;20:1-7. [[10.1186/s12944-021-01526-5](#)] [[PMID](#)]
- [119] Naderi Yaghouti AR, Zamanian H, Shalbfaf A. Machine learning approaches for early detection of non-alcoholic steatohepatitis based on clinical and blood parameters. *Scientific Reports*. 2024 Jan 30;14(1):2442. [[10.1038/s41598-024-51741-0](#)] [[PMID](#)]
- [120] Constantinescu EC, Udriștoiu AL, Udriștoiu ȘC, Iacob AV, Gruionu LG, Gruionu G, Săndulescu L, Săftoiu A. Transfer learning with pre-trained deep convolutional neural networks

- for the automatic assessment of liver steatosis in ultrasound images. *Medical Ultrasonography*. 2021 May 20;23(2):135-9. [[10.11152/mu-2746](https://doi.org/10.11152/mu-2746)] [PMID]
- [121] Sim KC, Kim MJ, Cho Y, Kim HJ, Park BJ, Sung DJ, Han NY, Han YE, Kim TH, Lee YJ. Radiomics analysis of magnetic resonance proton density fat fraction for the diagnosis of hepatic steatosis in patients with suspected non-alcoholic fatty liver disease. *Journal of Korean Medical Science*. 2022 Dec 19;37(49). [[10.3346/jkms.2022.37.e339](https://doi.org/10.3346/jkms.2022.37.e339)] [PMID]
- [122] Che H, Brown LG, Foran DJ, Noshier JL, Hachihaliloglu I. Liver disease classification from ultrasound using multi-scale CNN. *International Journal of Computer Assisted Radiology and Surgery*. 2021 Sep;16(9):1537-48. [[10.1007/s11548-021-02414-0](https://doi.org/10.1007/s11548-021-02414-0)] [PMID]
- [123] Park I, Kim N, Lee S, Park K, Son MY, Cho HS, Kim DS. Characterization of signature trends across the spectrum of non-alcoholic fatty liver disease using deep learning method. *Life Sciences*. 2023 Feb 1;314:121195. [[10.1016/j.lfs.2022.121195](https://doi.org/10.1016/j.lfs.2022.121195)] [PMID]
- [124] Sorino P, Caruso MG, Misciagna G, Bonfiglio C, Campanella A, Mirizzi A, Franco I, Bianco A, Buongiorno C, Liuzzi R, Cisternino AM. Selecting the best machine learning algorithm to support the diagnosis of Non-Alcoholic Fatty Liver Disease: A meta learner study. *PLoS One*. 2020 Oct 20;15(10):e0240867. [[10.1371/journal.pone.0240867](https://doi.org/10.1371/journal.pone.0240867)] [PMID]
- [125] Hwang JH, Kim HJ, Park H, Lee BS, Son HY, Kim YB, Jun SY, Park JH, Lee J, Cho JW. Implementation and practice of deep learning-based instance segmentation algorithm for quantification of hepatic fibrosis at whole slide level in Sprague-Dawley rats. *Toxicologic Pathology*. 2022 Feb;50(2):186-96. [[10.1177/01926233211057128](https://doi.org/10.1177/01926233211057128)] [PMID]
- [126] Yilmaz Y, Eren F. Identification of a support vector machine-based biomarker panel with high sensitivity and specificity for nonalcoholic steatohepatitis. *Clinica Chimica Acta*. 2012 Dec 24;414:154-7. [[10.1016/j.cca.2012.08.005](https://doi.org/10.1016/j.cca.2012.08.005)] [PMID]
- [127] Yen TJ, Yang CT, Lee YJ, Chen CH, Yang HC. Fatty liver classification via risk controlled neural networks trained on grouped ultrasound image data. *Scientific Reports*. 2024 Mar 28;14(1):7345. [[10.1038/s41598-024-57386-3](https://doi.org/10.1038/s41598-024-57386-3)] [PMID]
- [128] Zhang Z, Wang S, Zhu Z, Nie B. Identification of potential feature genes in non-alcoholic fatty liver disease using bioinformatics analysis and machine learning strategies. *Computers in biology and medicine*. 2023 May 1;157:106724. [[10.1016/j.combiomed.2023.106724](https://doi.org/10.1016/j.combiomed.2023.106724)] [PMID]
- [129] Sarvestany SS, Kwong JC, Azhie A, Dong V, Cerocchi O, Ali AF, Karnam RS, Kuriry H, Shengir M, Candido E, Duchon R. Development and validation of an ensemble machine learning framework for detection of all-cause advanced hepatic fibrosis: a retrospective cohort study. *The Lancet Digital Health*. 2022 Mar 1;4(3):e188-99. [[10.1016/S2589-7500\(21\)00270-3](https://doi.org/10.1016/S2589-7500(21)00270-3)] [PMID]
- [130] Banihashem SY, Shishehchi S. Ontology-Based decision tree model for prediction of fatty liver diseases. *Computer Methods in Biomechanics and Biomedical Engineering*. 2023 Apr 26;26(6):639-49. [[10.1080/10255842.2022.2081502](https://doi.org/10.1080/10255842.2022.2081502)] [PMID]
- [131] Deng Y, Ma Y, Fu J, Wang X, Yu C, Lv J, Man S, Wang B, Li L. A dynamic machine learning model for prediction of NAFLD in a health checkup population: A longitudinal study. *Heliyon*. 2023 Aug 1;9(8). [[10.1016/j.heliyon.2023.e18758](https://doi.org/10.1016/j.heliyon.2023.e18758)] [PMID]
- [132] Pickhardt PJ, Blake GM, Graffy PM, Sandfort V, Elton DC, Perez AA, Summers RM. Liver steatosis categorization on contrast-enhanced CT using a fully automated deep learning volumetric segmentation tool: evaluation in 1204 healthy adults using unenhanced CT as a reference standard. *American Journal of Roentgenology*. 2021 Aug 16;217(2):359-67. [[10.2214/AJR.20.24415](https://doi.org/10.2214/AJR.20.24415)] [PMID]
- [133] Oh TG, Kim SM, Caussy C, Fu T, Guo J, Bassirian S, Singh S, Madamba EV, Bettencourt R, Richards L, Ruth TY. A universal gut-microbiome-derived signature predicts cirrhosis. *Cell metabolism*. 2020 Nov 3;32(5):878-88. [[10.1016/j.cmet.2020.06.005](https://doi.org/10.1016/j.cmet.2020.06.005)] [PMID]
- [134] Weng S, Hu D, Chen J, Yang Y, Peng D. Prediction of fatty liver disease in a Chinese population using machine-learning algorithms. *Diagnostics*. 2023 Mar 18;13(6):1168. [[10.3390/diagnostics13061168](https://doi.org/10.3390/diagnostics13061168)] [PMID]
- [135] Han A, Byra M, Heba E, Andre MP, Erdman Jr JW, Loomba R, Sirlin CB, O'Brien Jr WD. Noninvasive diagnosis of nonalcoholic fatty liver disease and quantification of liver fat with radiofrequency ultrasound data using one-dimensional convolutional neural networks. *Radiology*. 2020 May;295(2):342-50. [[10.1148/radiol.2020191160](https://doi.org/10.1148/radiol.2020191160)] [PMID]
- [136] Jiang H, Hu Y, Zhang Z, Chen X, Gao JLiH, Disease. Identification of metabolic biomarkers associated with nonalcoholic fatty liver disease. 2023;22(1):150. [[10.1186/s12944-023-01911-2](https://doi.org/10.1186/s12944-023-01911-2)] [PMID]
- [137] Okanou T, Shima T, Mitsumoto Y, Umemura A, Yamaguchi K, Itoh Y, Yoneda M, Nakajima A, Mizukoshi E, Kaneko S, Harada K. Artificial intelligence/neural network system for the screening of nonalcoholic fatty liver disease and nonalcoholic steatohepatitis. *Hepatology Research*. 2021 May;51(5):554-69. [[10.1111/hepr.13628](https://doi.org/10.1111/hepr.13628)] [PMID]
- [138] Sowa JP, Atmaca Ö, Kahraman A, Schlattjan M, Lindner M, Sydor S, Scherbaum N, Lackner K, Gerken G, Heider D, Arteel GE. Non-invasive separation of alcoholic and non-alcoholic liver disease with predictive modeling. *PLoS One*. 2014 Jul 2;9(7):e101444. [[10.1371/journal.pone.0101444](https://doi.org/10.1371/journal.pone.0101444)] [PMID]
- [139] Acharya UR, Faust O, Molinari F, Sree SV, Junnarkar SP, Sudarshan V. Ultrasound-based tissue characterization and classification of fatty liver disease: A screening and diagnostic paradigm. *Knowledge-Based Systems*. 2015 Feb 1;75:66-77.
- [140] Peng HY, Duan SJ, Pan L, Wang MY, Chen JL, Wang YC, Yao SK. Development and validation of machine learning models for nonalcoholic fatty liver disease. *Hepatobiliary & Pancreatic Diseases International*. 2023 Dec 1;22(6):615-21. [[10.1016/j.hbpd.2023.03.009](https://doi.org/10.1016/j.hbpd.2023.03.009)] [PMID]
- [141] Liu Z, Wen H, Zhu Z, Li Q, Liu L, Li T, Xu W, Hou C, Huang B, Li Z, Dong C. Diagnosis of significant liver fibrosis in patients with chronic hepatitis B using a deep learning-based data integration network. *Hepatology International*. 2022 Jun;16(3):526-36. [[10.1007/s12072-021-10294-4](https://doi.org/10.1007/s12072-021-10294-4)] [PMID]
- [142] Özdil A, Yilmaz B. Medical infrared thermal image based fatty liver classification using machine and deep learning.

- Quantitative InfraRed Thermography Journal. 2024 Mar 14;21(2):102-19.
- [143] Byra M, Han A, Boehringer AS, Zhang YN, O'Brien Jr WD, Erdman Jr JW, Loomba R, Sirlin CB, Andre M. Liver fat assessment in multiview sonography using transfer learning with convolutional neural networks. *Journal of Ultrasound in Medicine*. 2022 Jan;41(1):175-84. [[10.1002/jum.15693](#)] [[PMID](#)]
- [144] Li G, Luo Y, Deng W, Xu X, Liu A, Song E. Computer aided diagnosis of fatty liver ultrasonic images based on support vector machine. In 2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society 2008 Aug 20 (pp. 4768-4771). IEEE. [[10.1109/EMBS.2008.4650279](#)] [[PMID](#)]
- [145] Rui F, Yeo YH, Xu L, Zheng Q, Xu X, Ni W, Tan Y, Zeng QL, He Z, Tian X, Xue Q. Development of a machine learning-based model to predict hepatic inflammation in chronic hepatitis B patients with concurrent hepatic steatosis: a cohort study. *EclinicalMedicine*. 2024 Feb 1;68. [[10.1016/j.eclinm.2023.102419](#)] [[PMID](#)]
- [146] Xing Y, Zhang P, Li X, Jin S, Xu M, Jia J, Wang HJ, Li L, Wang H. New predictive models and indices for screening MAFLD in school-aged overweight/obese children. *European Journal of Pediatrics*. 2023 Nov;182(11):5025-36. [[10.1007/s00431-023-05175-x](#)] [[PMID](#)]
- [147] Zhu H, Liu Y, Gao X, Zhang L. Combined CNN and pixel feature image for fatty liver ultrasound image classification. *Computational and Mathematical Methods in Medicine*. 2022;2022(1):9385734.
- [148] Dai S, Guo X, Liu S, Tu L, Hu X, Cui J, Ruan Q, Tan X, Lu H, Jiang T, Xu J. Application of intelligent tongue image analysis in conjunction with microbiomes in the diagnosis of MAFLD. *Heliyon*. 2024 Apr 15;10(7). [[10.1016/j.heliyon.2024.e29269](#)] [[PMID](#)]
- [149] Cao W, An X, Cong L, Lyu C, Zhou Q, Guo R. Application of deep learning in quantitative analysis of 2-dimensional ultrasound imaging of nonalcoholic fatty liver disease. *Journal of Ultrasound in Medicine*. 2020 Jan;39(1):51-9. [[10.1002/jum.15070](#)] [[PMID](#)]
- [150] Lin RH, Chuang CL. A hybrid diagnosis model for determining the types of the liver disease. *Computers in Biology and Medicine*. 2010 Jul 1;40(7):665-70. [[10.1016/j.compbiomed.2010.06.002](#)] [[PMID](#)]
- [151] Listopad S, Magnan C, Asghar A, Stolz A, Tayek JA, Liu ZX, Morgan TR, Norden-Krichmar TM. Differentiating between liver diseases by applying multiclass machine learning approaches to transcriptomics of liver tissue or blood-based samples. *JHEP Reports*. 2022 Oct 1;4(10):100560. [[10.1016/j.jhepr.2022.100560](#)] [[PMID](#)]
- [152] Khusial RD, Cioffi CE, Caltharp SA, Krasinskas AM, Alazraki A, Knight-Scott J, Cleeton R, Castillo-Leon E, Jones DP, Pierpont B, Caprio S. Development of a plasma screening panel for pediatric nonalcoholic fatty liver disease using metabolomics. *Hepatology communications*. 2019 Oct;3(10):1311-21. [[10.1002/hep4.1417](#)] [[PMID](#)]
- [153] Acharya UR, Koh JE, Hagiwara Y, Tan JH, Gertych A, Vijayanathan A, Yaakup NA, Abdullah BJ, Fabell MK, Yeong CH. Automated diagnosis of focal liver lesions using bidirectional empirical mode decomposition features. *Computers in biology and medicine*. 2018 Mar 1;94:11-8. [[10.1016/j.compbiomed.2017.12.024](#)] [[PMID](#)]
- [154] Qu H, Minacapelli CD, Tait C, Gupta K, Bhurwal A, Catalano C, Dafalla R, Metaxas D, Rustgi VK. Training of computational algorithms to predict NAFLD activity score and fibrosis stage from liver histopathology slides. *Computer Methods and Programs in Biomedicine*. 2021 Aug 1;207:106153. [[10.1016/j.cmpb.2021.106153](#)] [[PMID](#)]
- [155] Chen W, Zhang Y, Wu W, Yang H, Huang W. Machine learning-based predictive model for abdominal diseases using physical examination datasets. *Computers in Biology and Medicine*. 2024 May 1;173:108249. [[10.1016/j.compbiomed.2024.108249](#)] [[PMID](#)]
- [156] Liu YX, Liu X, Cen C, Li X, Liu JM, Ming ZY, Yu SF, Tang XF, Zhou L, Yu J, Huang KJ. Comparison and development of advanced machine learning tools to predict nonalcoholic fatty liver disease: An extended study. *Hepatobiliary & Pancreatic Diseases International*. 2021 Oct 1;20(5):409-15. [[10.1016/j.hbpd.2021.08.004](#)] [[PMID](#)]
- [157] Rehman MU, Najam S, Khalid S, Shafique A, Alqahani F, Baothman F, Shah SY, Abbasi QH, Imran MA, Ahmad J. Notice of Retraction: Infrared Sensing Based Non-Invasive Initial Diagnosis of Chronic Liver Disease Using Ensemble Learning. *IEEE Sensors Journal*. 2021 Jun 22;21(17):19395-406.
- [158] Wu CC, Yeh WC, Hsu WD, Islam MM, Nguyen PA, Poly TN, Wang YC, Yang HC, Li YC. Prediction of fatty liver disease using machine learning algorithms. *Computer methods and programs in biomedicine*. 2019 Mar 1;170:23-9. [[10.1016/j.cmpb.2018.12.032](#)] [[PMID](#)]
- [159] Li B, Tai DI, Yan K, Chen YC, Chen CJ, Huang SF, Hsu TH, Yu WT, Xiao J, Le L, Harrison AP. Accurate and generalizable quantitative scoring of liver steatosis from ultrasound images via scalable deep learning. *World Journal of Gastroenterology*. 2022 Jun 14;28(22):2494. [[10.3748/wjg.v28.i22.2494](#)] [[PMID](#)]
- [160] Wen W, Wu P, Zhang Y, Chen Z, Sun J, Chen H. Comprehensive analysis of NAFLD and the therapeutic target identified. *Frontiers in cell and developmental biology*. 2021 Sep 20;9:704704. [[10.3389/fcell.2021.704704](#)] [[PMID](#)]
- [161] Vianna P, Calce SI, Boustros P, Larocque-Rigny C, Patry-Beaudoin L, Luo YH, Aslan E, Marinos J, Alamri TM, Vu KN, Murphy-Lavallée J. Comparison of radiologists and deep learning for US grading of hepatic steatosis. *Radiology*. 2023 Oct 3;309(1):e230659. [[10.1148/radiol.230659](#)] [[PMID](#)]
- [162] Guo Z, Yu X, Fang Z, Yang K, Liu C, Dong Z, Liu C. The role of endoplasmic reticulum stress-related genes in the diagnosis and subtyping of non-alcoholic fatty liver disease. *General Physiology & Biophysics*. 2024 Mar 1;43(2). [[10.4149/gpb.2023042](#)] [[PMID](#)]
- [163] Sim KC, Kim MJ, Cho Y, Kim HJ, Park BJ, Sung DJ, Han YE, Han NY, Kim TH, Lee YJ. Diagnostic feasibility of magnetic resonance elastography radiomics analysis for the assessment of hepatic fibrosis in patients with nonalcoholic fatty liver disease. *Journal of Computer Assisted Tomography*. 2022 Jul 1;46(4):505-13. [[10.1097/RCT.0000000000001308](#)] [[PMID](#)]
- [164] Lee LW, Yen JB, Lu HK, Liao YS. Prediction of nonalcoholic fatty liver disease by anthropometric indices and bioelectrical

- impedance analysis in children. *Childhood Obesity*. 2021 Dec 1;17(8):551-8. [[10.1089/chi.2021.0054](https://doi.org/10.1089/chi.2021.0054)] [PMID]
- [165]Khan H, Srivastav A, Mishra AK, editors. Use of Classification Algorithms in Health Care 2020. [[10.1108/978-1-83909-099-820201007](https://doi.org/10.1108/978-1-83909-099-820201007)]
- [166]An Q, Rahman S, Zhou J, Kang JJ. A Comprehensive Review on Machine Learning in Healthcare Industry: Classification, Restrictions, Opportunities and Challenges. *Sensors (Basel)*. 2023;23(9):4178. [[10.3390/s23094178](https://doi.org/10.3390/s23094178)] [PMID]
- [167]Mahesh BJJoS, . R. Machine learning algorithms-a review. 2020;9(1):381-6 [[10.21275/ART20203995](https://doi.org/10.21275/ART20203995)]
- [168]Zemmal N, Azizi N, Sellami M, Zenakhra D, Cheriguene S, Dey N, et al. Robust feature selection algorithm based on transductive SVM wrapper and genetic algorithm: application on computer-aided glaucoma classification. 2018;17:310-46 [[10.1504/IJISTA.2018.094018](https://doi.org/10.1504/IJISTA.2018.094018)]
- [169]Tariq M, Al-Khasawneh MA, Irtaza G, Fiaz MW, Safi W, Asif RJCoBAfT, et al. Intelligent System to Diagnosis of Pneumonia in Children using Support Vector Machine. 2023:1-6 [[10.1109/ICBATSS7792.2023.10111167](https://doi.org/10.1109/ICBATSS7792.2023.10111167)]
- [170]Wulandari RI, Fa'rifah RY, Utama NIJCoDS, Applications I. Application of the Random Forest Algorithm for Breast Cancer Analysis with Data Balancing: Case Study at Al-Ihsan Hospital. 2024:254-9 [[10.1109/ICoDSA62899.2024.10651924](https://doi.org/10.1109/ICoDSA62899.2024.10651924)]
- [171]Blotwijk S, Raets C, Barbé KJIIsoMM, Applications. Exploratory study on Evolutionary Random Forests for Classification in Medical Datasets. 2023:1-6 [[10.1109/MeMeA57477.2023.10171908](https://doi.org/10.1109/MeMeA57477.2023.10171908)]
- [172]Meenakshi TJWPC. Automatic Detection of Diseases in Leaves of Medicinal Plants Using Modified Logistic Regression Algorithm. 2023;131:2573 - 97 [[10.1007/s11277-023-10555-5](https://doi.org/10.1007/s11277-023-10555-5)]
- [173]Liu LJCoR, System I. Research on Logistic Regression Algorithm of Breast Cancer Diagnose Data by Machine Learning. 2018:157-60 [[10.1109/ICRIS.2018.00049](https://doi.org/10.1109/ICRIS.2018.00049)]
- [174] Randhawan B, Jagtap R, Bhilawade A, Chaure DJJfRIAS, Technology E. Heart Disease Prediction Using Logistic Regression Algorithm. 2022 [[10.1088/1757-899X/1022/1/012072](https://doi.org/10.1088/1757-899X/1022/1/012072)]
- [175]Magrabi F, Ammenwerth E, McNair JB, De Keizer NF, Hyponen H, Nykanen P, et al. Artificial Intelligence in Clinical Decision Support: Challenges for Evaluating AI and Practical Implications. *Yearb Med Inform*. 2019;28(1):128-34. [[10.1055/s-0039-1677903](https://doi.org/10.1055/s-0039-1677903)] [PMID]
- [176]Durosini I, Pizzoli SFM, Strika M, Pravettoni G. Artificial intelligence and medicine: A psychological perspective on AI implementation in healthcare context. *Artificial Intelligence for Medicine: Elsevier*; 2024. p. 231-7. [[10.1016/B978-0-443-13671-9.00011-9](https://doi.org/10.1016/B978-0-443-13671-9.00011-9)]
- [177]Ryan DK, Maclean RH, Balston A, Scourfield A, Shah AD, Ross J. Artificial intelligence and machine learning for clinical pharmacology. *Br J Clin Pharmacol*. 2024;90(3):629-39. [[10.1111/bcp.15930](https://doi.org/10.1111/bcp.15930)] [PMID]
- [178]Lainjo BJJAI. Original Research Article A meta-study on optimizing healthcare performance with artificial intelligence and machine learning. 2024;7(5) [[10.32629/jai.v7i5.1535](https://doi.org/10.32629/jai.v7i5.1535)]
- [179]Handelman GS, Kok HK, Chandra RV, Razavi AH, Huang S, Brooks M, et al. Peering into the black box of artificial intelligence: evaluation metrics of machine learning methods. 2019;212(1):38-43 [[10.2214/ajr.18.20224](https://doi.org/10.2214/ajr.18.20224)] [PMID]
- [180]Martha S, Warangal T, Priya IMN. ROLE OF STATISTICS IN ARTIFICIAL INTELLIGENCE.
- [181]Decharatanachart P, Chaiteerakij R, Tiyyarattanachai T, Treeprasertsuk S. Application of artificial intelligence in non-alcoholic fatty liver disease and liver fibrosis: a systematic review and meta-analysis. *Therap Adv Gastroenterol*. 2021;14:17562848211062807. [[10.1177/17562848211062807](https://doi.org/10.1177/17562848211062807)] [PMID]
- [182]Mishra S, Tandon DRJIJOSRIE, MANAGEMENT. Federated Learning in Healthcare: A Path Towards Decentralized and Secure Medical Insights. 2024 [[10.1109/JIOT.2023.3329061](https://doi.org/10.1109/JIOT.2023.3329061)]
- [183]Tiwari RJJIJOSRIE, MANAGEMENT. The Use of AI and Machine Learning in Healthcare and its Potential to Improve Patient Outcomes. 2023
- [184]Johnson KW, Torres Soto J, Glicksberg BS, Shameer K, Miotto R, Ali M, et al. Artificial Intelligence in Cardiology. *J Am Coll Cardiol*. 2018;71(23):2668-79. [[10.1016/j.jacc.2018.03.521](https://doi.org/10.1016/j.jacc.2018.03.521)] [PMID]
- [185]Aung YYM, Wong DCS, Ting DSW. The promise of artificial intelligence: a review of the opportunities and challenges of artificial intelligence in healthcare. *Br Med Bull*. 2021;139(1):4-15. [[10.1093/bmb/ldab016](https://doi.org/10.1093/bmb/ldab016)] [PMID]
- [186]Familoni BTJJofIB, Research P. Ethical frameworks for AI in healthcare entrepreneurship: A theoretical examination of challenges and approaches. 2024



©2025 by the authors. Licensee AJUMS, Ahvaz, Iran. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution-NonCommercial 4.0 International (CC BY-NC 4.0 license) (<http://creativecommons.org/licenses/by-nc/4.0/>).