



پیش‌بینی شدت فیروز کبدی با استفاده از مدل‌های یادگیری ماشین

پیمان الماسی نژاد^۱، امین گلاب‌پور^{۲*}

۱- گروه مهندسی کامپیوتر و فناوری اطلاعات، دانشگاه پیام نور، تهران، ایران.

۲- گروه فن‌آوری اطلاعات سلامت، دانشکده پیراپزشکی، دانشگاه علوم پزشکی شاهرود، شاهرود، ایران.

تاریخ دریافت: ۱۴۰۳/۰۴/۲۳، تاریخ پذیرش: ۱۴۰۳/۰۷/۳۰

چکیده

مقدمه: برای تشخیص کبد چرب غیرالکلی معمولاً از آزمایش فیبرواسکن استفاده می‌شود که هزینه بالایی دارد. همچنین، آزمایشات کم‌هزینه مانند اندازه‌گیری آنزب

م‌های کبدی یا آزمایشات هماتولوژی نمی‌توانند کبد چرب را به‌طور قطعی تشخیص دهند و فقط به‌عنوان ابزارهای اولیه در تشخیص کبد چرب به‌کار می‌روند.

مواد و روش‌ها: در این پژوهش، یک مدل یادگیری ماشین برای تشخیص کبد چرب با استفاده از اطلاعات دموگرافیک، آنزیم‌های کبدی و آزمایشات هماتولوژی ارائه گردید. برای این کار، داده‌ها از پرونده ۱۰۷۸ مراجعه‌کننده به بیمارستان امام رضا (ع) سال‌های ۱۳۹۷ تا ۱۴۰۲ استخراج شده است که شامل ۲۵ متغیر وابسته می‌باشد. پس از پیش‌پردازش، اطلاعات به ۵۳۱ پرونده کاهش یافت. برای جایگزینی داده‌های گمشده از الگوریتم بهینه‌سازی ذرات چندهدفه استفاده شد. پس از پیش‌پردازش، الگوریتم ماشین‌بردار پشتیبان بر روی این داده‌ها اجرا گردید. در نهایت، عملکرد الگوریتم پیشنهادی با الگوریتم‌های مشابه مقایسه و ارزیابی شد.

نتایج: در مرحله پیش‌پردازش، رکوردهایی که بیش از ۲۰ درصد داده‌های گمشده داشتند حذف شدند و مابقی رکوردها جایگزینی شدند. سپس داده‌ها به دو مجموعه آموزش و تست با نسبت ۷۰-۳۰ تقسیم گردید. الگوریتم ماشین‌بردار پشتیبان با کرنل شعاعی بر روی داده‌های آموزشی اجرا شد و میزان حساسیت، ویژگی و صحت برای داده‌های آموزشی به ترتیب ۹۶/۲۴٪، ۹۰/۸۶٪ و ۹۳/۵۵٪ حاصل گردید و برای داده‌های تست ۸۰٪، ۷۷/۲۲٪ و ۷۸/۶۲٪ به‌دست آمد. همچنین، در این پژوهش نشان داده شد که الگوریتم ماشین‌بردار پشتیبان پیشنهادی نسبت به شش الگوریتم مشابه عملکرد بهتری دارد. **نتیجه‌گیری:** در این پژوهش نشان داده شده است که با استفاده از الگوریتم‌های یادگیری ماشین، می‌توان کبد چرب غیر الکلی را با هزینه پایین‌تری تشخیص داد.

واژه‌های کلیدی: یادگیری ماشین، فیروز کبدی، پیش‌بینی، ماشین‌بردار پشتیبان.

*نویسنده مسئول: شاهرود، میدان هفتم تیر، دانشگاه علوم پزشکی شاهرود، گروه فناوری اطلاعات سلامت، تلفن: ۰۲۳۳۲۳۹۵۰۵۴، نمابر: ۰۲۳۳۲۳۹۴۸۰۰۰، Email: a.golabpour@gmail.com

ارجاع: الماسی نژاد پیمان، گلاب‌پور امین. پیش‌بینی شدت فیروز کبدی با استفاده از مدل‌های یادگیری ماشین. مجله دانش و تندرستی در علوم پایه پزشکی ۱۴۰۳؛ ۱۹(۳): ۵۵-۶۳.

مقدمه

کبد، به وزن تقریبی ۱۵۰۰ گرم، بزرگ‌ترین اندام درونی و از مهم‌ترین عضوهای بدن انسان است که بدون آن ادامه حیات غیرممکن است (۱). بیماری‌های کبدی در جمله ده بیماری کشنده در جهان جای دارند؛ در ایران، حدود ۱۰ درصد از کل مرگ‌ها و در اروپا، بیماری‌های کبدی پس از ناراحتی قلبی، سرطان، سکته و بیماری‌های تنفسی پنجمین عامل مرگ و میر هستند (۲). بیماری کبد چرب، شایع‌ترین بیماری کبدی در دوره‌ی زمانی کنونی است و شیوع آن در حال افزایش است. بر اساس آمار سازمان جهانی بهداشت، بین ۲۵ تا ۳۰ درصد افراد جامعه مبتلا به درجاتی از کبد چرب هستند، و اکثریت افراد چاق دارای کبد چرب می‌باشند (۳).

بیوپسی کبد، که به‌عنوان استاندارد طلایی برای مرحله‌بندی فیروز کبد شناخته می‌شود، به‌دلیل ماهیت تهاجمی آن برای برخی از بیماران پرخطر مناسب نیست. این مسأله منجر به توسعه استراتژی‌های غیرتهاجمی جایگزین شده است که در دهه گذشته به‌طور گسترده‌ای مورد تحقیق قرار گرفته‌اند. اگرچه هیچ‌یک از روش‌های غیرتهاجمی به دقت بیوپسی نمی‌رسند، اما این روش‌ها اکنون به‌طور گسترده در کلینیک‌های کبدی برای تشخیص فیروز پیشرفته کبد مورد استفاده قرار می‌گیرند و توسط دستورالعمل‌های بین‌المللی توصیه شده‌اند (۴-۶). آزمایش‌های غیرتهاجمی بر دو رویکرد اصلی تکیه دارند: اندازه‌گیری سطوح بیومارکرهاي سرمی و اندازه‌گیری سفتی کبد با استفاده از تکنیک‌های الاستوگرافی مبتنی بر سونوگرافی یا رزونانس مغناطیسی. بیومارکرهاي سرمی شامل آزمایش‌های ساده و ارزان‌قیمت تا آزمون‌های پیچیده‌تر و ثبت‌شده‌ای مانند FibroTest و Fibrometer هستند (۷).

برای تشخیص کبد چرب، روش‌های مختلفی وجود دارد و یکی از متداول‌ترین آنها روش فیبرواسکن است. فیبرواسکن یک آزمایش غیرتهاجمی است که برای ارزیابی میزان سختی و فیروز کبد استفاده می‌شود. این آزمایش از امواج فراصوتی برای اندازه‌گیری الاستیسیته کبد استفاده می‌کند. بیمار در حالی که به پشت دراز کشیده، دستگاه فیبرواسکن روی ناحیه راست بالای شکم قرار می‌گیرد. امواج صوتی از طریق دستگاه به کبد فرستاده می‌شوند و بازتاب آنها اندازه‌گیری می‌شود. سرعت بازگشت امواج صوتی به دستگاه نشان‌دهنده میزان سختی کبد است؛ هرچه کبد سفت‌تر باشد، بازگشت امواج سریع‌تر خواهد بود که می‌تواند به تشخیص کبد چرب غیرالکلی کمک کند. این آزمایش بدون درد است و تنها چند دقیقه طول می‌کشد و نیازی به آمادگی خاصی قبل از انجام آن نیست. مطالعات نشان داده‌اند که صحت این آزمایش در تشخیص کبد چرب غیرالکلی بین ۸۰٪ تا ۹۰٪ است (۸ و ۹).

با این حال، هزینه انجام آزمایش فیبرواسکن بالا است (۱۰) و امکان اینکه برای همه افراد مشکوک به کبد چرب این آزمایش انجام شود،

امکان‌پذیر نیست. به همین دلیل، تشخیص کبد چرب به کمک اندازه‌گیری آنزیم‌های کبدی و آزمایشات هماتولوژی از روش‌های اولیه در پزشکی است. در این روش، میزان آنزیم‌های خاصی در خون اندازه‌گیری می‌شود تا اطلاعاتی در مورد سلامت کبد به دست آید. آنزیم‌های مهم کبدی که برای تشخیص اولیه کبد چرب اندازه‌گیری می‌شوند. با این حال، تشخیص نهایی کبد چرب معمولاً نیازمند ترکیب نتایج آزمایشات خونی با سایر روش‌های تشخیصی مانند فیبرواسکن است، زیرا بررسی آنزیم‌ها به تنهایی برای تشخیص کبد چرب کافی نیست.

یک مقاله مبتنی بر هوش مصنوعی برای تشخیص کبد چرب با استفاده از آنزیم‌های کبدی بهره برده است، توسط ییپ و همکاران انجام شده است. در این پژوهش، ۹۲۲ بیمار مورد بررسی قرار گرفتند و مدل‌های مختلف هوش مصنوعی شامل رگرسیون لجستیک، آداپوست و رگرسیون برای پیش‌بینی بیماری کبد چرب استفاده شد. مدل رگرسیون لجستیک با دقت ۸۸-۸۷٪ بهترین عملکرد را داشت و ویژگی‌های مرتبط مانند مقاومت به انسولین، تری‌گلیسیرید و آلانین آمینوترانسفراز به‌عنوان ورودی مدل استفاده شدند (۱۱).

در مقاله‌ای در سال ۲۰۲۰ توسط سورینو و همکاران، هشت الگوریتم مختلف یادگیری ماشین برای تشخیص کبد چرب غیرالکلی مقایسه شده‌اند. این الگوریتم‌ها شامل دسته‌بندی تجمعی، درخت تصمیم، بیزین ساده، نزدیک‌ترین همسایگی، شبکه عصبی مصنوعی، جنگل تصادفی، رگرسیون لجستیک و ماشین‌بردار پشتیبان هستند. مدل ماشین‌بردار پشتیبان بهترین عملکرد را داشت و به صحت ۶۸ درصد رسیده است (۱۲). مقاله‌ای توسط ماع و همکاران که ۱۱ الگوریتم یادگیری ماشین مختلف شامل رگرسیون لجستیک، نزدیک‌ترین همسایه، ماشین‌بردار پشتیبان و غیره را بررسی کرده‌اند. آنها دریافتند که رگرسیون لجستیک با دقت ۸۳/۴۱٪ و ماشین‌بردار پشتیبان با بالاترین دقت و اختصاصی بودن، بهترین عملکرد را برای تشخیص کبد چرب غیر الکلی داشته‌اند (۱۳). همچنین در مطالعه دیگری مدل‌های یادگیری ماشین مانند ماشین‌بردار پشتیبان و جنگل تصادفی نیز برای تشخیص کبد چرب در مردان و زنان به ترتیب با دقت‌های ۸۶/۹٪ و ۸۰٪ مورد استفاده قرار گرفتند (۱۴).

از آنجایی که بیماری‌های کبدی یکی از شایع‌ترین بیماری‌ها می‌باشند، تشخیص به موقع آن بسیار مهم می‌باشد. در حال حاضر برای تشخیص کبد چرب از روش فیبرواسکن که یک آزمایش غیرتهاجمی است، استفاده می‌گردد اما این آزمایش هزینه بالایی دارد لذا پژوهشگران با استفاده از اطلاعات دموگرافیک، آنزیم‌های کبدی و آزمایشات هماتولوژی برای پیش‌بینی شدت فیروز کبدی با استفاده از الگوریتم‌های یادگیری ماشین، مدلی را ساختند که این مدل می‌تواند به طور کمی در تشخیص کبد چرب و ارزیابی شدت فیروز کبدی مورد استفاده قرار گیرند.

بیمارستان امام رضا (ع) مشهد مراجعه کرده بودند، استخراج شده و همراه با آخرین وضعیت آنها تا پایان مطالعه در فرم ثبت اطلاعات ذخیره شده‌اند. سپس با بررسی مطالعات مشابه و پس از مشورت با پزشکان و با توجه به متغیرهایی که در پرونده‌ها ثبت می‌شود، ۲۵ متغیر مستقل از پرونده‌ها استخراج گردید (جدول ۱). از میان ۱۰۷۸ پرونده بیمار، ۵۴۷ پرونده به دلایلی مانند داده‌های گمشده یا خارج از بازه، حذف شده‌اند و در نهایت تنها ۵۳۱ پرونده قابل دسترسی برای تحلیل باقی مانده است.

پیش‌پردازش داده‌ها شامل دو مرحله حذف داده‌های خارج از بازه و برخورد با داده‌های گمشده است. در مرحله حذف داده‌های خارج از بازه از روش IQR (InterQuartile Range) استفاده گردید (۱۶) که منجر به شناسایی ۴۳ رکورد با داده‌های خارج از بازه شد. همچنین ۵۰۴ رکورد با گمشدگی بالای ۲۰ درصد شناسایی و حذف شدند. از ۵۳۱ رکورد باقی‌مانده، ۴۷۳ رکورد دارای گمشدگی کمتر از ۲۰ درصد بودند که با استفاده از الگوریتم جایگزینی بهینه‌سازی ذرات چند هدفه تکمیل شدند (۱۷).

ب-ارایه مدل پیش‌بینی

مدل پیش‌بینی به کمک اطلاعات دموگرافیک و آزمایش خون میزان فیبرواسکن کبد را محاسبه می‌کند. فیبرواسکن به دو بازه کمتر از هفت کیلو پاسکال و بیشتر از هفت کیلوپاسکال تقسیم شده است (۸ و ۱۸). داده‌ها به دو مجموعه آموزشی و آزمون تقسیم شدند. مدل پیش‌بینی با استفاده از داده‌های آموزشی طراحی و سپس توسط داده‌های تست ارزیابی گردید. ساختار تقسیم داده‌ها به دو مجموعه آموزشی و آزمون از روش K-Fold استفاده شد که مقدار K برابر ده در نظر گرفته شده است. الگوریتم پس از صد بار اجرا و صد بار محاسبه سه شاخص حساسیت (Sensitivity)، ویژگی (Specificity) و صحت (۱۰)، میانگین هر سه شاخص به‌عنوان خروجی در نظر گرفته شد. علت اجرای صد بار الگوریتم این است که بتوان حالت‌های متفاوتی از انتخاب داده‌های آموزشی و تست در کل داده‌ها مشاهده شود. فرایند مدل پیشنهادی در شکل ۳ بیان شده است.

ج-مقایسه با الگوریتم‌های دیگر:

در این بخش، داده‌های آموزشی مدل پیشنهادی به شش الگوریتم نزدیک‌ترین همسایگی، درخت تصمیم، شبکه عصبی مصنوعی، جنگل تصادفی، بی‌زین ساده و رگرسیون لجستیک داده شد. سپس، هر شش الگوریتم با داده‌های آزمون مورد ارزیابی قرار گرفت. در ادامه، سه شاخص حساسیت، ویژگی و صحت شش الگوریتم با الگوریتم ماشین بردار پشتیبان مقایسه شد. ساختار مقایسه با الگوریتم‌های دیگر در شکل ۲ نشان داده شده است.

در این پژوهش، هدف استفاده از اطلاعات دموگرافیک، آنزیم‌های کبیدی و نتایج آزمایشات هماتولوژی برای آرایه مدلی مبتنی بر الگوریتم‌های یادگیری ماشین جهت پیش‌بینی شدت فیروز کبیدی است. این رویکرد به‌منظور کاهش وابستگی به روش‌های پرهزینه‌ای مانند فیبرواسکن، که معمولاً برای تشخیص شدت فیروز کبیدی به‌کار می‌رود، پیشنهاد شده است. استفاده از الگوریتم‌های یادگیری ماشین در این زمینه، نه تنها می‌تواند به بهبود دقت و سرعت تشخیص این بیماری کمک کند، بلکه با استفاده از داده‌های قابل دسترس‌تری مانند نتایج آزمایشات خونی و اطلاعات دموگرافیک، امکان ارزیابی فیروز کبیدی را با هزینه‌های کمتر فراهم می‌آورد. توانایی یادگیری ماشین پیشنهادی در پردازش حجم زیادی از داده‌ها و شناسایی الگوهای پنهان است که ممکن است با روش‌های سنتی کمتر مشهود باشد. در نتیجه، الگوریتم‌های مبتنی بر هوش مصنوعی می‌توانند به‌عنوان ابزارهای کمکی در کنار روش‌های بالینی معمول، به تشخیص زود هنگام و مدیریت بهتر بیماران مبتلا به کبد چرب غیرالکلی و فیروز کبیدی کمک کنند. این مدل‌ها همچنین می‌توانند به پزشکان این امکان را بدهند که ارزیابی‌های دقیق‌تری از میزان پیشرفت بیماری داشته و در نهایت با آرایه یک رویکرد اقتصادی‌تر، منجر به کاهش هزینه‌های درمانی و بهبود نتایج بالینی شوند.

مواد و روش‌ها

در این پژوهش، ابتدا به بررسی و تحلیل متغیرهای مستقل پرداخته شده و سپس داده‌ها به دو مجموعه مجزا، شامل داده‌های آموزشی و تست، تقسیم شده‌اند. برای پیش‌بینی شدت فیروز کبیدی، الگوریتم ماشین بردار پشتیبان با استفاده از کرنل پایه شعاعی (RBF: Radial Basis Function Kernel) به‌کار گرفته شده است. این الگوریتم به دلیل قدرت بالایی که در تفکیک داده‌های غیرخطی دارد، انتخاب مناسبی برای مدل‌سازی این مسأله پیچیده به شمار می‌آید (۱۵).

در ادامه، به‌منظور ارزیابی دقیق عملکرد مدل پیشنهادی، این الگوریتم با شش مدل پیش‌بینی دیگر مورد مقایسه قرار گرفته است. این مقایسه‌ها شامل تحلیل دقت، حساسیت، ویژگی و سایر شاخص‌های عملکردی مرتبط بوده که هدف آن بررسی میزان کارایی و برتری الگوریتم پیشنهادی در مقابل سایر روش‌هاست. این رویکرد جامع به منظور اطمینان از عملکرد بهینه مدل و آرایه دقیق‌ترین پیش‌بینی‌ها در تشخیص فیروز کبیدی مورد استفاده قرار گرفته است.

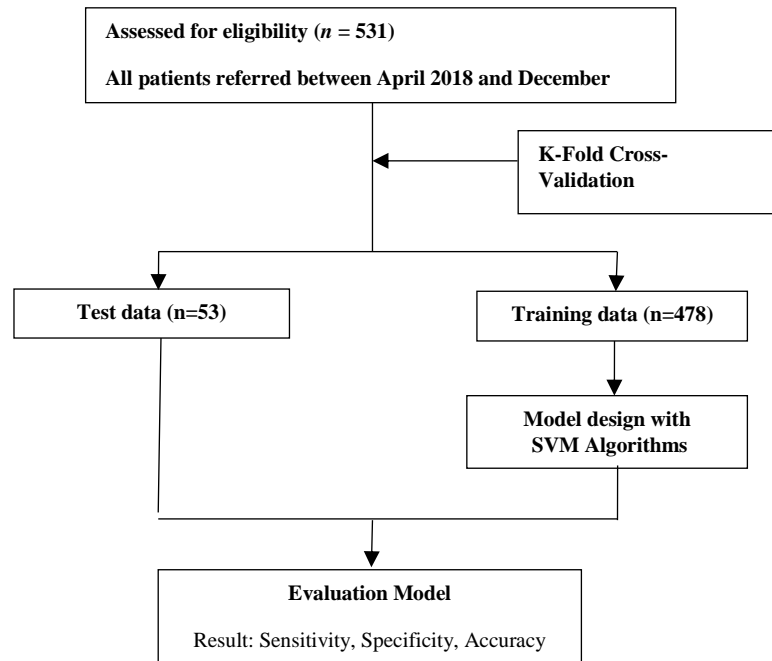
الف- داده‌ها مطالعه

در این پژوهش، از نوع گذشته‌نگر استفاده شده است و به بررسی شدت آسیب‌های کبیدی بالغین پرداخته شده است. اطلاعات از پرونده‌های ۱۰۷۸ بیمار مبتلا به کبد چرب، که در سال‌های ۱۳۹۷ تا ۱۴۰۲ برای درمان به

جدول ۱- مشخصات متغیرهای مستقل و وابسته

ردیف	نام متغیر	نوع متغیر	توضیحات
۱	Gender	اسمی	تعداد مرد = ۲۹۴ زن = ۲۳۷
۲	Age	نسبتی	سن بیماران که حداقل ۱۶ سال و حداکثر ۸۸ سال است
۳	Height	رتبه‌ای	قد بیمار که حداقل ۱۴۹ سانتی‌متر و حداکثر ۱۹۵ سانتی‌متر است
۴	Weight	رتبه‌ای	وزن بیمار که حداقل ۲۵ کیلوگرم و حداکثر ۱۱۹ کیلوگرم است
۵	waist circumference	نسبتی	میزان دور شکم است که حداقل آن ۶۵ سانتی‌متر و حداکثر آن ۱۴۰ سانتی‌متر است
۶	Diabetes	اسمی	تعداد ۱۰۳ بیمار دیابت دارند و ۴۲۸ بیمار دیابت ندارد
۷	History of HTN (History of high blood pressure)	اسمی	سابقه فشار خون
۸	Hypercholesterolemia	اسمی	افزایش کلسترول
۹	Hypertriglyceridemia	اسمی	افزایش تری‌گلیسرید
۱۰	FBS (Fasting Blood Sugar)	نسبتی	میزان قند خون است که حداقل آن ۳۹ و حداکثر آن ۲۵۰ است
۱۱	Cholesterol	نسبتی	میزان کلسترول است که حداقل آن ۴۰ و حداکثر آن ۳۱۰ است
۱۲	cholesterol	اسمی	اگر کلسترول کمتر از ۲۰۰ باشد به معنی No و اگر بیشتر مساوی ۲۰۰ باشد به معنی Yes است
۱۳	TG (Triglycerides)	نسبتی	میزان چربی بیمار است و حداقل آن ۲۱ و حداکثر آن ۵۳۰ است.
۱۴	LDL (Low-density lipoprotein)	نسبتی	کلسترول بد است که حداقل آن ۲۳ و حداکثر آن ۲۲۰ می‌باشد.
۱۵	HDL (High-density lipoprotein)	نسبتی	کلسترول خوب است که حداقل آن ۲۰ و حداکثر آن ۹۵ می‌باشد.
۱۶	AST(SGOT) (Aspartate Aminotransferase Serum Glutamic-Oxaloacetic Transaminase)	نسبتی	آنزیم کبدی حداقل آن ۹ و حداکثر آن ۲۴۵ است.
۱۷	ALT (SGPT) (Alanine Aminotransferase Serum Glutamic-Pyruvic Transaminase)	نسبتی	آنزیم کبدی حداقل آن ۹ و حداکثر آن ۲۹۳ است.
۱۸	ALP (Alkaline Phosphatase)	نسبتی	آنزیم کبدی حداقل آن ۲۱ و حداکثر آن ۷۱۵ است.
۱۹	Conjugated bilirubin	نسبتی	Conjugated Bilirubin حداقل آن ۰/۲ و حداکثر آن ۶/۴ است.
۲۰	Fe	نسبتی	میزان آهن خون است و حداقل آن ۲۹ و حداکثر آن ۲۷۳ است.
۲۱	Hematocrit	نسبتی	میزان Hematocrit بیمار است و حداقل آن ۶/۲ است و حداکثر آن ۳۹/۷ است.
۲۲	Platelets	نسبتی	میزان پلاکت خون است و حداقل آن ۱۸۶۰۰ و حداکثر آن ۲۱۷۰۰۰ است.
۲۳	Ferritin	نسبتی	میزان Ferritin بیمار است و حداقل آن ۸ و حداکثر آن ۸۰۰ است.
۲۴	Size Liver	رتبه‌ای	به سه قسمت Small, normal و Large تقسیم می‌شود.
۲۵	BMI	نسبتی	میزان BMI بیمار و حداقل آن ۱۸/۷۲ و حداکثر آن ۴۴/۹۲ است.
۲۶	Fibroscan	اسمی	Fibroscan <7=242, Fibroscan ≥ 7=289
ردیف	نام متغیر	نوع متغیر	توضیحات
۱	Gender	اسمی	تعداد مرد = ۲۹۴ زن = ۲۳۷
۲	Age	نسبتی	سن بیماران که حداقل ۱۶ سال و حداکثر ۸۸ سال است
۳	Height	رتبه‌ای	قد بیمار که حداقل ۱۴۹ سانتی‌متر و حداکثر ۱۹۵ سانتی‌متر است
۴	Weight	رتبه‌ای	وزن بیمار که حداقل ۲۵ کیلوگرم و حداکثر ۱۱۹ کیلوگرم است
۵	waist circumference	نسبتی	میزان دور شکم است که حداقل آن ۶۵ سانتی‌متر و حداکثر آن ۱۴۰ سانتی‌متر است
۶	Diabetes	اسمی	تعداد ۱۰۳ بیمار دیابت دارند و ۴۲۸ بیمار دیابت ندارد
۷	History of HTN(History of high blood pressure)	اسمی	سابقه فشار خون
۸	Hypercholesterolemia	اسمی	افزایش کلسترول
۹	Hypertriglyceridemia	اسمی	افزایش تری‌گلیسرید
۱۰	FBS (Fasting Blood Sugar)	نسبتی	میزان قند خون است که حداقل آن ۳۹ و حداکثر آن ۲۵۰ است
۱۱	Cholesterol	نسبتی	میزان کلسترول است که حداقل آن ۴۰ و حداکثر آن ۳۱۰ است
۱۲	cholesterol	اسمی	اگر کلسترول کمتر از ۲۰۰ باشد به معنی No و اگر بیشتر مساوی ۲۰۰ باشد به معنی Yes است
۱۳	TG (Triglycerides)	نسبتی	میزان چربی بیمار است و حداقل آن ۲۱ و حداکثر آن ۵۳۰ است.
۱۴	LDL (Low-density lipoprotein)	نسبتی	کلسترول بد است که حداقل آن ۲۳ و حداکثر آن ۲۲۰ می‌باشد.
۱۵	HDL (High-density lipoprotein)	نسبتی	کلسترول خوب است که حداقل آن ۲۰ و حداکثر آن ۹۵ می‌باشد.
۱۶	AST(SGOT: Aspartate Aminotransferase Serum Glutamic-Oxaloacetic Transaminase)	نسبتی	آنزیم کبدی حداقل آن ۹ و حداکثر آن ۲۴۵ است.
۱۷	ALT (SGPT: Alanine Aminotransferase Serum Glutamic-Pyruvic Transaminase)	نسبتی	آنزیم کبدی حداقل آن ۹ و حداکثر آن ۲۹۳ است.
۱۸	ALP (Alkaline Phosphatase)	نسبتی	آنزیم کبدی حداقل آن ۲۱ و حداکثر آن ۷۱۵ است.
۱۹	Conjugated bilirubin	نسبتی	Conjugated Bilirubin حداقل آن ۰/۲ و حداکثر آن ۶/۴ است.
۲۰	Fe	نسبتی	میزان آهن خون است و حداقل آن ۲۹ و حداکثر آن ۲۷۳ است.
۲۱	Hematocrit	نسبتی	میزان Hematocrit بیمار است و حداقل آن ۶/۲ است و حداکثر آن ۳۹/۷ است.

نسبتی	میزان پلاکت خون است و حداقل آن ۱۸۶۰۰ و حداکثر آن ۲۱۷۰۰۰۰ است.	Platelets	۲۲
نسبتی	میزان Ferritin بیمار است و حداقل آن ۸ و حداکثر آن ۸۰۰ است.	Ferritin	۲۳
رتبه‌ای	به سه قسمت Small, normal و Large تقسیم می‌شود.	Size Liver	۲۴
نسبتی	میزان BMI بیمار و حداقل آن ۱۸/۷۲ و حداکثر آن ۴۴/۹۲ است.	BMI	۲۵
اسمی	7=289 <7 = 242, Fibroscan ≥ Fibroscan	Fibroscan	۲۶



شکل ۱- حل مسأله به کمک الگوریتم پیشنهادی

نتایج

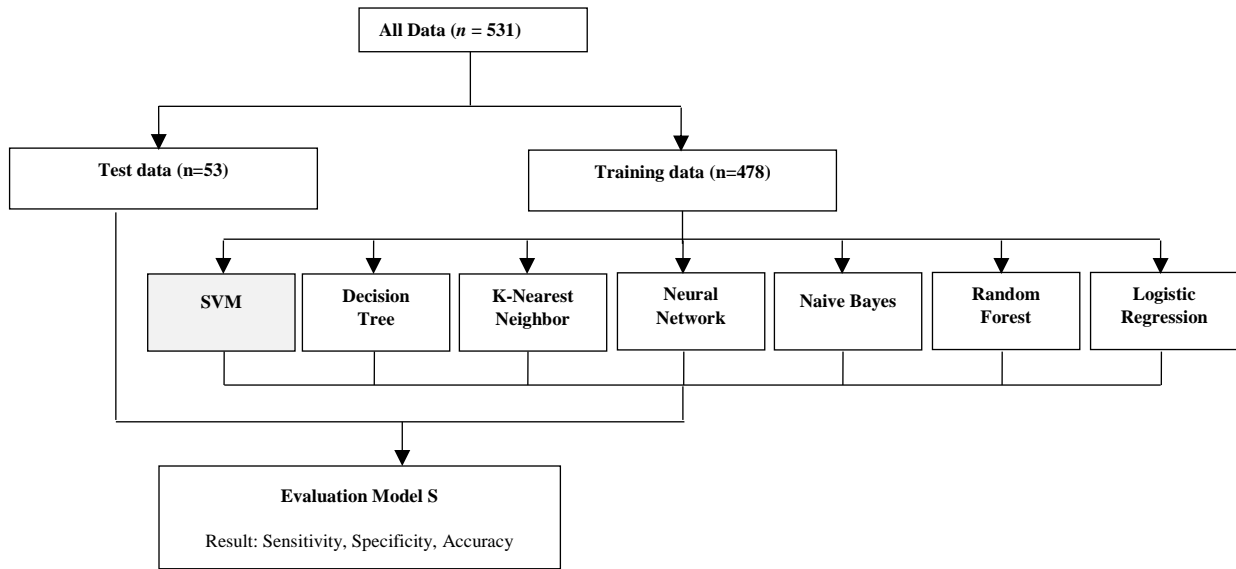
همان‌طور که در جدول ۴ مشاهده می‌شود، الگوریتم انتخاب شده نسبت به الگوریتم‌های مشابه از نظر صحت ۳/۴۳ درصد تا ۱۳/۶ درصد بهتر عمل کرده است.

بحث

روش‌های یادگیری ماشینی در حوزه پزشکی، به‌عنوان یکی از ابزارهای مهم و کارآمد، به پزشکان در تشخیص و پیش‌بینی بیماری‌ها کمک بسیاری می‌کنند. این تکنولوژی به دلیل توانایی در کار با داده‌ها و اطلاعات بسیار زیاد، می‌تواند در تشخیص سریعتر بیماری‌ها و کمک به تصمیم‌گیری‌های پزشکان مؤثر باشد. هدف از این مطالعه این است که از انجایی که بیماری کبدی در دسته بیماری‌های شایع قرار دارد و تشخیص به موقع آن اهمیت زیادی دارد، با استفاده از اطلاعات دموگرافیک بیمار، آنزیم‌های کبدی و آزمایشات هماتولوژی بتوان شدت فیروز کبدی را پیش‌بینی کرد. در حال حاضر از روش فیبرواسکن استفاده می‌گردد این روش در دسته روش‌های غیر تهاجمی است ولی هزینه بسیار بالایی دارد امکان استفاده از آن برای همه افراد مشکوک به کبد چرب، امکان‌پذیر نیست. لذا می‌توانیم با کمک مدل‌های تشخیصی با عملکرد مناسب، کاهش خطاها و هزینه را داشته باشیم.

در این مرحله، جهت ارزیابی مدل پیشنهادی داده‌های آموزشی به الگوریتم ماشین‌بردار پشتیبان داده شد. بعد از بررسی داده‌ها، نتایج مبین آن بود که ارتباط بین متغیرهای وابسته و مستقل غیرخطی است؛ بنابراین از کرنل پایه شعاعی استفاده شده است. دو شاخص C و sigma کرنل پایه شعاعی به ترتیب ۱ و ۱/۸ در نظر گرفته شده‌اند. این مقادیر با روش سعی و خطا محاسبه شده‌اند. پس از تنظیم شاخص‌ها، الگوریتم ماشین‌بردار پشتیبان ۱۰۰ بار اجرا گردید و شاخص‌های ارزیابی مطابق جدول ۲ محاسبه شده‌اند.

خروجی الگوریتم ماشین‌بردار پشتیبان در جدول ۳ مشاهده می‌شود. همان‌طور که ملاحظه می‌شود، عملکرد الگوریتم پیشنهادی قابل قبول است. الگوریتم ماشین‌بردار پشتیبان از نظر صحت با شش الگوریتم دیگر مقایسه شده است. برای این منظور، همان داده‌های آموزشی و تست به هر شش الگوریتم داده شده‌اند. در جدول ۴، مقایسه صحت الگوریتم پیشنهادی با سایر الگوریتم‌ها مشاهده می‌شود.



شکل ۲ - مقایسه الگوریتم‌ها با مدل پیشنهادی

جدول ۲- شاخص‌های ارزیابی (۱۹)

شاخص	مقدار
حساسیت	$Sensitivity = \frac{\text{Number of true positives}}{\text{Total number of sick individuals in population}}$
ویژگی	$Specificity = \frac{\text{Number of true negatives}}{\text{Total number of well individuals in population}}$
صحت	$Accuracy = \frac{\text{Correct Classifications}}{\text{All Classifications}}$
ارزش اخباری مثبت	$PPV = \frac{\text{Number of true positives}}{\text{Number of Positive calls}}$
ارزش اخباری منفی	$NPV = \frac{\text{Number of true negatives}}{\text{Number of negatives calls}}$

جدول ۳- خروجی مدل پیشنهادی

Data	Sensitivity	Specificity	Accuracy	PPV	NPV
(۴۷۸)Data Training	۹۶/۲۴ ± ۰/۸۳	۹۰/۸۶ ± ۰/۶۱	۹۳/۵۵ ± ۰/۷۷	۹۱/۳۳ ± ۰/۷۸	۹۶/۰۲ ± ۰/۳۹
(۵۳)Test	۸۰/۰۰ ± ۲/۶۱	۷۷/۲۲ ± ۱/۵۸	۷۸/۶۲ ± ۳/۰۲	۷۸/۰۵ ± ۲/۱۹	۷۹/۲۲ ± ۲/۶

جدول ۴- مقایسه الگوریتم پیشنهادی با شش الگوریتم دیگر

Algorithm	Accuracy
Decision Tree	۷۳/۶۲ ± ۱/۲۳
K-Nearest Neighbor	۶۹/۹۱ ± ۱/۹۱
Neural Network	۷۴/۲ ± ۴/۷۱
Naive Bayes	۶۸/۴۱ ± ۱/۳
Random Forest	۷۵/۱۹ ± ۲/۱۲
Logistic Regression	۶۵/۰۲ ± ۱/۰۶
proposed model(SVM)	۷۸/۶۲ ± ۳/۰۲

مسائلی مانند سوگیری الگوریتمی، کیفیت داده‌ها و انتساب مسئولیت می‌تواند بر قابلیت اطمینان سیستم‌های هوش مصنوعی پزشکی تأثیر بگذارد و اعتماد بیمار و پزشک به این فناوری‌ها را کاهش دهد (۲۹).

بنابراین، یک چارچوب اخلاقی جامع که سلامت انسان را اولویت‌بندی می‌کند، مدیریت کیفیت داده‌ها را تقویت می‌کند، شفافیت الگوریتم را افزایش می‌دهد و همکاری بین‌المللی را ترویج می‌کند، برای ایجاد تشخیص هوش مصنوعی قابل اعتماد و اخلاقی در پزشکی ضروری است (۲۹). به همین دلیل توصیه می‌شود این مدل برای داده‌های مشابه در بیمارستان‌های دیگر نیز مورد استفاده قرار گیرد تا عملکرد آن تأیید شود.

یکی از محدودیت‌های اصلی این پژوهش، عدم دسترسی به داده‌های جامع‌تر در پرونده‌های بیماران بود. اطلاعات موجود تنها شامل داده‌های دموگرافیک، آنزیم‌های کبدی و آزمایشات هماتولوژی بود، در حالی که متغیرهای مهمی مانند سابقه مصرف داروها، مکمل‌ها، سیگار کشیدن و سابقه خانوادگی بیماری‌های کبدی که نقش اساسی در پیشرفت و ابتلا به بیماری‌های کبدی دارند، در دسترس نبود. این مسأله می‌تواند بر دقت و جامعیت مدل پیشنهادی تأثیر داشته باشد. علاوه بر این، مدل ارائه‌شده تنها بر اساس داده‌های بیماران یک مرکز درمانی توسعه داده شده است، که ممکن است به محدودیت در تعمیم نتایج به سایر جمعیت‌های بیمار منجر شود. پیشنهاد می‌شود در پژوهش‌های آتی، از داده‌های متنوع‌تر و شامل سوابق پزشکی کامل‌تر استفاده شود تا دقت مدل بهبود یابد و قابلیت تعمیم آن افزایش یابد. این محدودیت‌ها باید مدنظر قرار گیرند و به‌عنوان نقاط قابل بهبود در تحقیقات آینده مورد توجه قرار گیرند تا مدل‌های پیش‌بینی بهتری برای فیروز کبدی توسعه داده شوند.

تشکر و قدردانی

سیاس ویژه‌ای دارم از دکتر سعید اسلامی بابت همکاری ارزشمندشان و در اختیار قرار دادن داده‌های لازم برای این پژوهش. تلاش و حمایت ایشان نقش مهمی در پیشبرد این تحقیق داشته است.

تعارض منافع

در این مقاله هیچ‌گونه تعارض منافع وجود ندارد.

حمایت مالی

این مطالعه هیچ‌گونه حمایت مالی دریافت نکرده است.

ملاحظات اخلاقی

در این پژوهش، تمامی ملاحظات اخلاقی رعایت شده. داده‌ها به‌صورت محرمانه و ناشناس مورد استفاده قرار گرفته‌اند.

مشارکت نویسندگان

در بخش مشارکت نویسندگان، آنالیز داده‌ها توسط الماسی‌نژاد انجام شد. طراحی و ارزیابی مدل بر عهده گلاب‌پور بود. نگارش مقاله توسط

پس از بررسی مطالعات و استفاده از نظر پزشکان در زمینه متغیرهای مورد نیاز جهت ایجاد مدل، ۲۵ متغیر استخراج شدند که شامل اطلاعات دموگرافیک بیمار، آنزیم‌های کبدی و آزمایشات هماتولوژی بودند. الگوریتم‌های مختلفی جهت بررسی کارایی مورد استفاده قرار گرفتند. یک الگوریتم مبتنی بر ماشین‌بردار پشتیبان برای پیش‌بینی فیروز کبدی توسعه داده شده است که در مقایسه با شش الگوریتم دیگر یادگیری ماشین عملکرد بهتری داشته است. این مدل با استفاده از داده‌های دموگرافیک، آنزیم‌های کبدی و آزمایشات خون، به‌طور مؤثری توانسته دقت پیش‌بینی فیروز کبدی را بهبود بخشد. برتری ماشین‌بردار پشتیبان در این پژوهش بین ۳ تا ۱۳ درصد بوده و نشان‌دهنده کارایی بالای این الگوریتم در تشخیص و مدیریت فیروز کبدی در مقایسه با روش‌های دیگر است.

درست است که عملکرد مدل در مجموعه تست نسبت به مجموعه آموزشی پایین‌تر گزارش شده، اما این مسئله تا حد زیادی ناشی از روش تقسیم ۳۰-۷۰ داده‌ها است. با توجه به اینکه مدل تنها با ۷۰ درصد از داده‌ها آموزش دیده، طبیعی است که عملکرد در داده‌های تست کاهش یابد. با این حال، دقت بیش از ۷۵ درصد در داده‌های تست نشان می‌دهد که مدل عملکرد مناسبی دارد و همچنان قادر به تعمیم نتایج به داده‌های جدید است. این کاهش عملکرد بین مجموعه‌های آموزشی و تست در مدل‌های یادگیری ماشین امری رایج است و اغلب به‌عنوان بخشی از فرآیند ارزیابی صحیح مدل پذیرفته می‌شود، زیرا هدف اصلی مدل‌ها توانایی تعمیم‌پذیری آنها به داده‌های نادیده است. همچنین مشخص گردید با استفاده از الگوریتم یادگیری ماشین، می‌توان میزان فیروز کبدی را با خطایی کمتر از ۲۵ درصد پیش‌بینی نمود. که این حاکی از کارایی بالا مدل ایجاد شده به کمک هوش مصنوعی می‌باشد.

مطالعات مختلفی این مسئله را تأیید کرده‌اند (۱ و ۲۰)، هرچند که برخی مطالعات دیگر (۲۱ و ۲۲) آن را رد کرده‌اند. با این حال، در این پژوهش نشان داده شد که الگوریتم‌های یادگیری ماشین می‌توانند مسائل پیچیده و غیرخطی را پیش‌بینی نمایند (۲۳) همچنین، الگوریتم ماشین‌بردار پشتیبان که یک الگوریتم غیرخطی است (۲۴)، نسبت به الگوریتم خطی رگرسیون عملکرد بهتری دارد. بنابراین، مشخص گردید که آنزیم‌های کبدی با شدت فیروز کبدی ارتباط غیرخطی دارند.

در مطالعات مختلفی استفاده از هوش مصنوعی برای تشخیص کبد چرب اثبات شده است (۱۴، ۲۵ و ۲۶) استفاده از هوش مصنوعی در تشخیص کبد چرب هم مزایای قابل توجهی و هم چالش‌های اخلاقی را به همراه دارد. ابزارهای مبتنی بر هوش مصنوعی پتانسیل ارتقای خدمات بهداشتی و درمانی با بهبود دقت تشخیص و کارایی درمان را دارند (۲۷ و ۲۸). با این حال، ملاحظات اخلاقی مانند سوگیری، شفافیت، مسئولیت‌پذیری و پاسخگویی باید با دقت مورد توجه قرار گیرد تا از استقرار ایمن و موثر هوش مصنوعی در محیط‌های بالینی اطمینان حاصل شود.

14. Mahzari A. Artificial intelligence in nonalcoholic fatty liver disease. *Egyptian Liver Journal* 2022;12:69. doi: 10.1186/s43066-022-00224-w
15. Steinwart I, Christmann A. *Support Vector Machines*: Springer New York; 2008.9780387772424
16. Mishra P, Pandey CM, Singh U, Gupta A, Sahu C, Keshri A. Descriptive statistics and normality tests for statistical data. *Ann Card Anaesth* 2019;22:67-72. doi: 10.4103/aca.ACA_157_18
17. Almasinejad P, Golabpour A, Mollakhalili Meybodi MR, Mirzaie K, Khosravi A. A Dynamic Model for Imputing Missing Medical Data: A Multiobjective Particle Swarm Optimization Algorithm. *J Healthc Eng* 2021;2021:1203726. doi: 10.1155/2021/1203726
18. Hartmann C. *EASL Clinical Practice Guidelines on genetic cholestatic liver diseases 2024* [Available from: <https://easl.eu/publication-category/clinical-practice-guidelines/>].
19. Sammut C, Webb GI. *Encyclopedia of machine learning and data mining*: Springer Publishing Company, Incorporated; 2017.148997685X
20. Khodadoostan M, Shariatifar B, Motamedi N, Abdolahi H. Comparison of liver enzymes level and sonographic findings value with liver biopsy findings in nonalcoholic fatty liver disease patients. *Advanced Biomedical Research* 2016;5:40. doi: 10.4103/2277-9175.178785
21. Jamwal R, Barlock BJ. Nonalcoholic fatty liver disease (NAFLD) and hepatic cytochrome P450 (CYP) enzymes. *Pharmaceuticals* 2020;13:222. doi: 10.3390/ph13090222
22. Donati G, Stagni B, Piscaglia F, Venturoli N, Morselli-Labate A, Rasciti L, et al. Increased prevalence of fatty liver in arterial hypertensive patients with normal liver enzymes: role of insulin resistance. *Gut* 2004;53:1020-3. doi: 10.1136/gut.2003.027086
23. Le DM, Greene ML, Makumi WA, Dixon WE. Real-time modular deep neural network-based adaptive control of nonlinear systems. *IEEE Control Systems Letters* 2021;6:476-81. doi: 10.1109/LCSYS.2021.3081361
24. Lin R-H. An intelligent model for liver disease diagnosis. *Artificial Intelligence in Medicine* 2009;47:53-62. doi: 10.1016/j.artmed.2009.05.005
25. 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;13:5080. doi: 10.3390/app13085080
26. Alshagathrh FM, Househ MS. Artificial intelligence for detecting and quantifying fatty liver in ultrasound images: A systematic review. *Bioengineering* 2022;9:748. doi: 10.3390/bioengineering9120748
27. Elasan S. Artificial Intelligence (AI) and Ethics in Medicine at a Global Level: Benefits and Risks. *Current Researches in Health Sciences-II*. 2023;51. doi: 10.58830/ozgur.pub128.c508
28. Jha D, Rauniyar A, Srivastava A, Hagos DH, Tomar NK, Sharma V, et al. Ensuring trustworthy medical artificial intelligence through ethical and philosophical principles. *arXiv preprint arXiv:230411530*. 2023. doi: 10.48550/arXiv.2304.11530
29. Zhang J, Zhang Z-m. Ethics and governance of trustworthy medical artificial intelligence. *BMC Medical Informatics and Decision Making* 2023;23:7. doi: 10.1186/s12911-023-02103-9

الماسی نژاد صورت گرفت و بررسی نهایی مقاله توسط هر دو نویسنده انجام شد.

کد اخلاق

IR.MUMS.MEDICAL.REC.1402.512

References

1. Aishwarya A, Terry O. Statins in Alcoholic and Non-Alcoholic Fatty Liver Disease and Chronically Elevated Liver Enzymes. *International Journal of Clinical Medicine* 2022;13:229-52. doi: 10.4236/ijcm.2022.137020
2. Farhood B, Raei B, Malekzadeh R, Shirvani M, Najafi M, Mortezaazadeh T. A review of incidence and mortality of colorectal, lung, liver, thyroid, and bladder cancers in Iran and compared to other countries. *Contemporary Oncology/Współczesna Onkologia* 2019;23:7-15. doi: 10.5114/wo.2019.84112
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;64:73-84. doi: 10.1002/hep.28431
4. Marchesini G, Roden M, Vettor R. Response to: Comment to “EASL-EASD-EASO Clinical Practice Guidelines for the management of non-alcoholic fatty liver disease”. *Journal of Hepatology* 2017;66:466-7. doi: 10.1016/j.jhep.2016.11.002
5. Liver EAftSot. *EASL-ALEH Clinical Practice Guidelines: Non-invasive tests for evaluation of liver disease severity and prognosis*. *Journal of Hepatology* 2015;63:237-64. doi: 10.1016/j.jhep.2015.04.006
6. Ferraioli G, Wong VW-S, Castera L, Berzigotti A, Sporea I, Dietrich CF, et al. Liver ultrasound elastography: an update to the world federation for ultrasound in medicine and biology guidelines and recommendations. *Ultrasound in Medicine & Biology* 2018;44:2419-40. doi: 10.1016/j.ultrasmedbio.2018.07.008
7. Castera L. Non-invasive tests for liver fibrosis in NAFLD: creating pathways between primary healthcare and liver clinics. *Liver International* 2020;40:77-81. doi: 10.1111/liv.14347
8. Violi F, Basili S, Raparelli V, Chowdary P, Gatt A, Burroughs A. Patients with liver cirrhosis suffer from primary haemostatic defects? Fact or fiction? *Journal of Hepatology* 2011;55:1415-27. doi: 10.1016/j.jhep.2011.06.008
9. Carlson JJ, Kowdley KV, Sullivan SD, Ramsey SD, Veenstra DL. An evaluation of the potential cost-effectiveness of non-invasive testing strategies in the diagnosis of significant liver fibrosis. *Journal of Gastroenterology and Hepatology* 2009;24:786-91. doi: 10.1111/j.1440-1746.2009.05778.x
10. Tsochatzis EA, Crossan C, Longworth L, Gurusamy K, Rodriguez-Peralvarez M, Mantzoukis K, et al. Cost-effectiveness of noninvasive liver fibrosis tests for treatment decisions in patients with chronic hepatitis C. *Hepatology* 2014;60:832-43. doi: 10.1002/hep.27296
11. Yip TF, Ma A, Wong VS, Tse YK, Chan HY, Yuen PC, et al. Laboratory parameter-based machine learning model for excluding non-alcoholic fatty liver disease (NAFLD) in the general population. *Alimentary Pharmacology & Therapeutics* 2017;46:447-56. doi: 10.1111/apt.14172
12. Sorino P, Caruso MG, Misciagna G, Bonfiglio C, Campanella A, Mirizzi A, et al. Selecting the best machine learning algorithm to support the diagnosis of Non-Alcoholic Fatty Liver Disease: A meta learner study. *PLoS One* 2020;15:e0240867. doi: 10.1371/journal.pone.0240867
13. 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 Res Int* 2018;2018:4304376. doi: 10.1155/2018/4304376





Predicting Liver Fibrosis Severity Using Machine Learning Models

Peyman Almasi Nejad (Ph.D.)¹, Amin Golabpour (Ph.D.)^{*2}

1- Faculty Member of the Dept. of Computer Engineering and Information Technology, Payame Noor University, Tehran, Iran.

2- School of Allied Medical Sciences, Shahroud University of Medical Sciences, Shahroud, Iran.

Received: 13 July 2024, Accepted: 21 October 2024

Abstract:

Introduction: The diagnosis of NAFLD typically involves the use of the FibroScan test, which can be costly. More affordable options, like liver enzyme and hematology tests, cannot diagnose fatty liver disease; they only serve as preliminary tools for its diagnosis.

Methods: In this study, a machine-learning model was developed to diagnose fatty liver disease using demographic information, liver enzymes, and hematology tests. Data was extracted from the records of 1078 patients who visited Haj Marafi Hospital between 2018 and 2023, encompassing 25 dependent variables. After preprocessing, the data was reduced to 531 records. A multi-objective particle swarm optimization algorithm was used to impute missing data. Following preprocessing, a support vector machine (SVM) algorithm was applied to the data, and the performance of the proposed algorithm was compared and evaluated against similar algorithms.

Results: During preprocessing, records with more than 20% missing data were removed, and the remaining data were imputed. The data was then divided into training and testing sets (70-30 split). The radial basis function (RBF) SVM was applied to the training data, resulting in sensitivity, specificity, and accuracy of 96.24%, 90.86%, and 93.55%, respectively. For the test data, these rates were 80%, 77.22%, and 78.62%.

Conclusion: This study demonstrated that machine learning algorithms can diagnose NAFLD more cost-effectively.

Keywords: Machine Learning, Liver Fibrosis, Prediction, Support Vector Machine.

Conflict of Interest: No

*Corresponding author: A. Golabpour, Email: a.golabpour@gmail.com

Citation: Almasi Nejad P, Golabpour A. Predicting liver fibrosis severity using machine learning models. Journal of Knowledge & Health in Basic Medical Sciences 2024;19(3):55-63.

