

Comparison of Synthetic Performance with Conventional Methods on Guideline in Predictive Diagnosis: A Systematic Review

Kimia Zarooj Hosseini¹, Reihane Taheri², Amin Golabpour^{2*}

1. Student Research Committee, Department of Health Information Technology and Management, School of Allied Medical Sciences, Shahid Beheshti University of Medical Sciences, Tehran, Iran

2. Department of Health Information Technology, School of Allied Medical Sciences, Shahrood University of Medical Sciences, Shahrood, Iran

Abstract

Background: Diabetes is a serious global health problem, and effective methods for its prediction and management are essential. Conventional diagnostic approaches typically rely on tests such as oral glucose tolerance test (OGTT), fasting plasma glucose (FPG) and glycated hemoglobin (HbA1c). Machine learning has the potential to enhance diagnostic accuracy; however, its performance and alignment with clinical guidelines require thorough evaluation.

Methods: This narrative review examines the effectiveness of machine learning in the early diagnosis of diabetes. Articles were selected based on predefined criteria and analyzed in terms of algorithm classification, output measures, involvement of clinical experts, and interpretability. Evaluation metrics such as accuracy, area under the curve (AUC), specificity and sensitivity were used to assess algorithmic performance. Relevant studies comparing prediabetes diagnosis using artificial intelligence and conventional methods were reviewed, and clinical guidelines from both domains were extracted and compared.

Results: Analysis of 41 articles showed that ANN, LR, and DNN were the most frequently used algorithms. Only 2% of the studies incorporated clinical rules and physician involvement, and 12% demonstrated model interpretability. While conventional methods rely on HbA1c and FPG tests, no clinical guidelines currently exist for AI-based diagnosis. Machine learning algorithms outperformed traditional methods, showing 29% higher sensitivity and 23% higher specificity.

Conclusion: Although artificial intelligence demonstrates superior performance in prediabetes diagnosis, limitations such as lack of interpretability and the absence of standardized clinical guidelines hinder its current clinical application. Addressing these challenges could enable AI to become a more efficient and reliable diagnostic tool.

Keywords: Artificial Intelligence, Diabetes, Machine Learning, Clinical Guidelines

Please cite this article as:

Zarooj Hosseini K, Taheri R, Golabpour A. Comparison of synthetic performance with conventional methods on guideline in predictive diagnosis: a systematic review. *ijld*. 2025; 25(5):381-394.

DOI: [10.18502/ijdl.v25i5.20334](https://doi.org/10.18502/ijdl.v25i5.20334)

*Corresponding Author: Amin Golabpour; Email: a.golabpour@shmu.ac.ir

Shahrood University of Medical Sciences and Health Services, Hafte Tir Square, Shahrood, Iran. Tel: +982332395054, Fax: +982332395009



مقایسه عملکرد هوش مصنوعی با روش‌های مرسوم مبتنی بر گایدلاین در تشخیص پیش دیابت: یک مطالعه مروری نظام مند

کیما زروج حسینی^۱، ریجانه طاهری^۲، امین گلابپور^{۳*}

۱- کمیته تحقیقات دانشجویی، گروه فناوری اطلاعات و مدیریت سلامت، دانشکده پیراپزشکی، دانشگاه علوم پزشکی شهید بهشتی، تهران، ایران

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

چکیده

مقدمه: دیابت یک مشکل جدی جهانی است و روش‌های پیش‌بینی و مدیریت آن اهمیت زیادی دارند. روش‌های تشخیصی مرسوم شامل آزمایش‌هایی مانند OGTT، FPG و HbA1c است. یادگیری ماشین می‌تواند دقت تشخیصی را بهبود بخشد، اما نیاز به بررسی گایدلاین‌های بالینی و عملکرد آن در مقایسه با روش‌های مرسوم وجود دارد.

روش‌ها: این مرور روایتی اثربخشی یادگیری ماشینی در تشخیص زودهنگام دیابت را بررسی می‌کند. مقالات براساس معیارهای مشخص انتخاب و از نظر طبقه‌بندی الگوریتم‌ها، شاخصهای خروجی، مشارکت متخصصان بالینی و شفافیت تحلیل شدند. معیارهایی مانند دقت، AUC، ویژگی و حساسیت برای ارزیابی عملکرد الگوریتم‌ها استفاده شدند. مقالات مرتبط برای مقایسه تشخیص پیش دیابت با هوش مصنوعی و روش‌های مرسوم بررسی شدند و گایدلاین‌های هر دو حوزه استخراج و مقایسه شدند.

یافته‌ها: تحلیل ۴۱ مقاله نشان داد که الگوریتم‌های ANN، LR و DNN بیشترین استفاده را داشته‌اند. تنها ۲ درصد مقالات از قوانین بالینی و حضور پزشکان استفاده کرده و ۱۲ درصد از مقالات قابلیت تفسیر داشته‌اند. در روش‌های مرسوم از تست‌های HbA1c و FPG استفاده می‌شود، اما هیچ گایدلاین بالینی برای هوش مصنوعی منتشر نشده است. الگوریتم‌های هوش مصنوعی در حساسیت و ویژگی به ترتیب ۲۹ و ۲۳ درصد بهتر عمل کردند. **نتیجه‌گیری:** اگرچه هوش مصنوعی در تشخیص پیش دیابت عملکرد بهتری دارد، اما به دلیل مشکلاتی مانند عدم ارزیابی پذیری و نبود گایدلاین‌های بالینی، هنوز برای استفاده در بالین آماده نیست. با رفع این محدودیت‌ها، هوش مصنوعی می‌تواند به‌عنوان روشی کارآمدتر به‌کار رود.

واژگان کلیدی: هوش مصنوعی، دیابت، یادگیری ماشین، گایدلاین‌های بالینی

تاریخ پذیرش: ۱۴۰۳/۱۲/۲۰

تاریخ دریافت: ۱۴۰۳/۰۷/۳۰

به این مقاله، به صورت زیر استناد کنید:

Zaroor Hosseini K, Taheri R, Golabpour A. Comparison of synthetic performance with conventional methods on guideline in predictive diagnosis: a systematic review. *ijldl*. 2025; 25(5):298-329.

* نویسنده مسئول: امین گلابپور، آدرس: شاهرود، میدان هفتم تیر، دانشگاه علوم پزشکی و خدمات بهداشتی درمانی شاهرود، تلفن:

۰۲۳-۲۲۲۹۵۰۰۷، نمابر: ۰۲۳-۲۲۲۹۵۰۰۷، پست الکترونیک: a.golabpour@shmu.ac.ir

مقدمه

دیابت یکی از بزرگ‌ترین چالش‌های بهداشتی در جهان محسوب می‌شود و به‌عنوان یک بیماری مزمن، از دیدگاه سلامت جهانی اهمیت ویژه‌ای دارد. این بیماری تاکنون بیش از ۴۲۰ میلیون نفر را در سراسر جهان تحت تأثیر قرار داده است و پیش‌بینی می‌شود که این رقم تا سال ۲۰۴۵ به ۷۰۰ میلیون نفر افزایش یابد [۱]. در هر ۱۰ ثانیه، دو نفر به دیابت مبتلا می‌شوند که معادل نزدیک به ۱۰ میلیون مورد جدید در سال است [۲]. همچنین، و در هر هفت ثانیه، یک نفر به دلیل عوارض ناشی از این بیماری جان خود را از دست می‌دهد [۳]. در سال ۲۰۲۱، تقریباً ۶۷ میلیون مرگ به دیابت یا عوارض مرتبط با آن نسبت داده شده است [۴]. تشخیص به موقع دیابت بسیار مهم و حیاتی است، زیرا می‌تواند از ایجاد عوارض جانبی جدی ناشی از دیابت مانند بیماری‌های قلبی-عروقی، نارسایی کلیوی، مشکلات اعصابی و پای دیابتی در افراد جلوگیری کرده و به افراد کمک کند تا بهبود یابند. همچنین تحقیقات نشان داده است که افراد مبتلا به دیابت که تازه تشخیص داده می‌شوند، درمان مناسب را فوراً دریافت می‌کنند و دچار مشکلات کمتری ناشی از این بیماری می‌شوند که این موضوع تأثیر قابل ملاحظه‌ای در کاهش مرگ‌ومیر و ناخوشی‌های ناشی از دیابت دارد.

روش‌های یادگیری ماشینی در حوزه پزشکی، به‌عنوان یکی از ابزارهای مهم و کارآمد، به پزشکان در تشخیص و پیش‌بینی بیماری‌ها کمک بسیاری می‌کنند. این فناوری به دلیل توانایی در کار با داده‌ها و اطلاعات بسیار زیاد، می‌تواند در تشخیص سریع‌تر بیماری‌ها و کمک به تصمیم‌گیری‌های پزشکان مؤثر باشد. در بیماران دیابت، این روش‌ها اهمیت زیادی دارند. توسط تحلیل دقیق داده‌های بیماری، می‌توانند به تشخیص دقیق‌تر و سریع‌تر کمک کرده و همچنین در پیش‌بینی احتمال ابتلا به دیابت نیز مورد استفاده قرار می‌گیرند. این موارد به پزشکان کمک می‌کند تا افرادی که در خطر ابتلا به دیابت هستند را زودتر تشخیص دهند. علاوه بر این، به دلیل حجم بالای داده‌های پزشکی که نیاز به تحلیل دارند، یادگیری ماشینی می‌تواند در توسعه رویکردهای بهبود یافته برای مدیریت دیابت نیز به‌شدت مؤثر باشد.

الگوریتم‌های پیش‌بینی دیابت الگوریتم‌های داده‌کاوی است، داده‌کاوی یک روش تحلیلی است که در آن از تکنیک‌های مختلف استخراج داده برای کشف الگوها، ارتباطات و اطلاعات مفید استفاده می‌شود. این روش عموماً برای اکتشاف الگوها و روابط پنهان در

داده‌های بزرگ استفاده می‌شود که به‌طور معمول در داده‌هایی که حجم بالا، انواع مختلف و پیچیده‌ای از اطلاعات را شامل می‌شوند، موجود هستند با توجه به نوع پیش‌بینی که یک الگوریتم انجام می‌دهد، می‌توان الگوریتم‌ها را به دو دسته اصلی تقسیم کرد: الگوریتم‌های پیش‌بینی کننده و الگوریتم‌های گذشته‌نگر. الگوریتم‌های پیش‌بینی کننده براساس داده‌های موجود به پیش‌بینی یک متغیر یا رویداد در آینده می‌پردازند. این الگوریتم‌ها معمولاً از مدل‌سازی ریاضی، یادگیری ماشین، شبکه‌های عصبی و الگوریتم‌های تکنیکال مدل‌سازی استفاده می‌شود مانند پیش‌بینی سری زمانی، مدل‌های پیش‌بینی تقاضا در بازار و... [۵]. الگوریتم‌های گذشته‌نگر به تجزیه و تحلیل داده‌های موجود برای استخراج الگوها، روابط و ویژگی‌های مهم پرداخته و برای توصیف و تفسیر داده‌ها استفاده می‌شوند. معمولاً از تکنیک‌های مختلف داده‌کاوی، آماری و محاسباتی برای تحلیل داده‌ها استفاده می‌شود. مانند: الگوریتم‌های خوشه‌بندی، تحلیل عاملی، نمودارهای مختلف و آمارهای توصیفی. در دسته‌بندی دیگری الگوریتم‌ها مسائل بهینه‌سازی به دو دسته «دسته سفید» و «دسته سیاه» تقسیم می‌شوند، الگوریتم‌های «دسته سیاه» یا «Black Box» متعلق به دسته دوم هستند. این الگوریتم‌ها به این عنوان شناخته می‌شوند چون به شکل مستقیم با مدل مسئله سر و کار ندارند و فقط براساس تابع هدف و محدودیت‌های مسئله عمل می‌کنند و هیچ‌گونه اطلاعی از عملکرد و درون آن در اختیار کاربر نیست و عملکرد آن غیرشفاف است. الگوریتم‌های جعبه‌های سفید یا «White Box»، الگوریتم‌هایی هستند که ساختار و روند کاری داخلی آنها به‌طور کامل قابل مشاهده و درک است. این الگوریتم‌ها عموماً برای اهداف آموزشی، آزمایشی و تحقیقی به‌کار می‌روند. توانایی درک و تفسیر کامل روند کاری آنها، از ویژگی‌های اصلی این دسته از الگوریتم‌هاست [۶، ۷].

پیش دیابت حالتی از اختلال در تنظیم گلوکز است که مقدم بر دیابت است که با سطح گلوکز خون بالاتر از حد طبیعی مشخص می‌شود و با افزایش خطر قلبی-عروقی همراه است [۸]. این بیماری از طریق آزمایش‌های خونی مانند سطوح آزمون تحمل گلوکز خوراکی^۱ (OGTT)، قند خون ناشنا^۲ (FPG) و هموگلوبین گلیکوزیله^۳ (HbA1c) تشخیص داده می‌شود [۹]. هموگلوبین گلیکوزیله یک نشانگر زیستی شناخته شده برای تشخیص و نظارت بر دیابت و پیش دیابت در جمعیت‌ها و مطالعات مختلف است که منعکس کننده میانگین سطح گلوکز خون در یک دوره ۶ تا ۸ هفته است [۱۰، ۱۱]. گلوکز پلاسما ناشتا یک ابزار تشخیصی است که

³ Glycated Hemoglobin

¹ Oral Glucose Tolerance Test

² Fasting Plasma Glucose

از آنها به دقت بالا، AUC و سایر معیارهای عملکرد دست یافتند. اما به‌طور کلی نتایج بیان‌کننده آن بود که، الگوریتم درخت تصمیم نتایج بهتری را نشان داد و به دقت ۹۰/۰۴ درصد در تشخیص دیابت نوع دو دست یافت [۱۶].

هدف از این مطالعه، مروری بر مطالعاتی است که در زمینه استفاده از یادگیری ماشین در تشخیص دیابت است تا بتوان میزان اثربخشی یادگیری ماشین را در تشخیص دیابت بررسی کرد؛ لذا با بررسی متون هم‌راستا به میزان و چگونگی استفاده و کاربرد این روش، میزان کمک در تسریع و دقت تشخیص بیماری، میزان دقت و سرعت به‌کارگیری درمان در نهایت چگونگی بهبود وضعیت بیمار، جلوگیری از عوارض، ترخیص بیمار از بیمارستان کمک به درمانگر در جهت سرعت و دقت تشخیص بیماری پرداخته شد. همچنین بررسی می‌شود که آیا روش‌های هوش مصنوعی به‌صورت راهنمای بالینی در تشخیص پیش دیابت مورداستفاده قرار می‌گیرد و عملکرد روش‌های هوش مصنوعی با گایدلاین‌های غیر هوش مصنوعی در تشخیص پیش دیابت مورد تجزیه و تحلیل قرار می‌گیرد و از سویی دیگر وضعیت کلی پژوهش‌ها در این زمینه مشخص می‌شود و با معرفی مواردی که امکان بررسی بیشتر را دارد امکان کار بیشتر در این حوزه برای سایر پژوهشگران فراهم می‌گردد.

روش‌ها

مطالعه حاضر یک مرور سیستماتیک در بازه زمانی ۲۰۰۶ تا ۲۰۲۴ است که با هدف بررسی میزان اثربخشی یادگیری ماشین در تشخیص و پیش‌بینی زود هنگام بیماری دیابت و مقایسه کارایی و اثربخشی این روش‌ها در مقایسه با روش‌های سنتی ذکر شده در گایدلاین‌های پزشکی انجام شده است. این مطالعه در دو مرحله انجام شده است: در مرحله اول، مقالات براساس معیارهای اولیه انتخاب و از پایگاه‌های داده استنادی استخراج شدند، در مرحله دوم، شاخصهای کلیدی از مقالات منتخب استخراج و مورد بررسی قرار گرفتند. در نگارش این مطالعه مروری از مقالات نمایه شده در پایگاه‌های اطلاعاتی scopus, pubmed, web of science استفاده شد. عبارت‌های مورد استفاده جهت جستجو در جدول ۱ آمده است. در این جستجو از کلمات کلیدی learning, Machine diabetes, diagnosis استفاده شده است. در راهبرد جستجو برای بازیابی مقالات مرتبط با حوزه، مفاهیم سه

برای ارزیابی سطح گلوکز خون پس از یک دوره ناشتا، معمولاً یک شبه، برای شناسایی پیش‌دیابت و دیابت استفاده می‌شود [۱۲]. این روش‌های تشخیصی به شناسایی افرادی کمک می‌کنند که ممکن است با کمک اقدامات پیشگیرانه باعث به تأخیر انداختن یا جلوگیری از شروع دیابت بشوند [۱۳، ۸].

در مطالعه‌ای در سال ۲۰۲۳ [۱۴] به بررسی پیشرفت‌های اخیر در استفاده از هوش مصنوعی (AI) در مدیریت دیابت و بحث درباره فرصت‌ها و چالش‌های استفاده از هوش مصنوعی در عملیات بالینی پرداخته شده است نتایج مبین آن بود که هوش مصنوعی در مدیریت دیابت، با تمرکز بر پیشرفت‌ها، فرصت‌ها و چالش‌ها، یک فرصت بزرگ برای بهبود مدیریت بیماری دیابت است و بر شاخص، دقیق و شخصی شدن مراقبت از دیابت از طریق یادگیری ماشین و هوش مصنوعی تأکید می‌شود. همچنین از پزشک جهت تحلیل برخی از داده‌ها، لیبیل کردن و نظارت بر داده‌ها و ارسال آن به سرور مرکزی هوش مصنوعی نیز استفاده شده است.

مطالعه‌ای در سال ۲۰۲۱ [۱۵] با عنوان بررسی جامع تکنیک‌های یادگیری ماشین برای تشخیص دیابت انجام شد که هدف از این مطالعه ارزیابی دقت تشخیص دیابت با استفاده از تکنیک‌های یادگیری ماشین، مقایسه‌های بین عملکرد این تکنیک‌ها و روش‌های سنتی تشخیص دیابت، شناسایی عوامل تأثیرگذار در تشخیص دیابت، و پیشنهادات برای بهبود روش‌های تشخیص دیابت با استفاده از یادگیری ماشین بود. این مقاله به این نتیجه می‌رسد که تشخیص دقیق دیابت بسیار حیاتی است و مدل‌های یادگیری عمیق، از شبکه‌های عصبی مصنوعی تا شبکه‌های عصبی بازگشتی، توانایی بازده بیشتری در پیش‌بینی بیماری با دقت بیشتر دارند.

مطالعه‌ای که در سال ۲۰۲۰ با هدف بررسی و تحلیل استفاده از روش‌های یادگیری ماشین و هوش مصنوعی در تحقیقات دیابت شیرین انجام شد که الگوریتم‌های مورد استفاده در مقالات شامل: شبکه عصبی کانولوشن^۱ (CNN)، رگرسیون لجستیک^۲ (LR)، پرسپترون چند لایه^۳ (MLP)، درخت تصمیم^۴ (DT)، سیستم استنتاج عصبی فازی تطبیقی^۵ (ANFIS)، و جنگل تصادفی^۶ (RF) بودند که الگوریتم‌ها براساس معیارهای عملکردی مانند دقت، حساسیت، ویژگی، سطح زیر منحنی^۷ (AUC)، F-Score، دقت، امتیاز کاپا، ارزش پیش‌بینی مثبت^۸ (PPV) و ارزش پیش‌بینی منفی^۹ (NPV) مقایسه شدند. نتایج در مطالعات مختلف متفاوت بود و برخی

⁷ Random Forest

⁸ Area Under the Curve

⁹ Positive Predictive Value

¹⁰ Negative Predictive Value

¹ Artificial Intelligence

² Convolutional Neural Network

³ Logistic Regression

⁴ Multilayer Perceptron

⁵ Decision Tree

⁶ Adaptive Neuro-Fuzzy Inference System

حوزه با استفاده از عملگرهای بولین با همدیگر ترکیب شده‌اند.

جدول ۱ - متن راهبرد جستجو در سه پایگاه داده

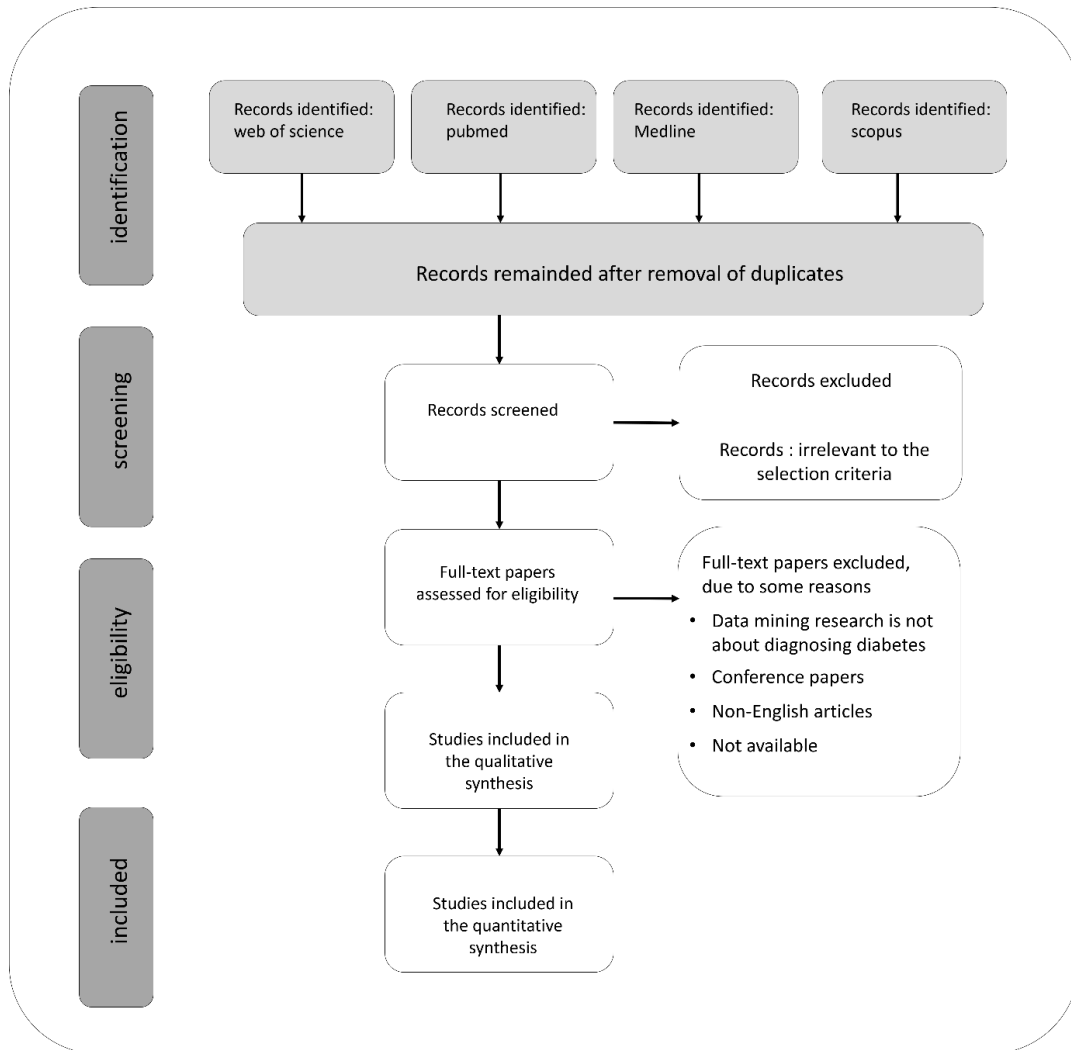
پایگاه داده	عبارت جستجو	Date of search
Pumped	((Diagnosis [MeSH Terms] AND (Diabetes Mellitus [MeSH Terms])) AND (Artificial Intelligence [MeSH Terms])) AND (Machine Learning [MeSH Terms])	04/10/1403
Scopus	TITLE-ABS (("Diagnoses" OR "Diagnose" OR "Diagnoses and Examinations" OR "Examinations and Diagnoses" OR "Diagnoses and Examination" OR "Examination and Diagnoses" OR "Postmortem Diagnosis" OR "Diagnoses, Postmortem" OR "Diagnosis, Postmortem" OR "Postmortem Diagnoses" OR "Antemortem Diagnosis" OR "Antemortem Diagnoses" OR "Diagnoses, Antemortem" OR "Diagnosis, Antemortem" OR "diagnosis" OR "diagnostic" OR "diagnosing" OR "diagnosed") AND ("Adult-Onset Diabetes Mellitus" OR "Ketosis-Resistant Diabetes Mellitus" OR "Diabetes Mellitus, Non Insulin Dependent" OR "Type 2 Diabetes Mellitus" OR "Diabetes Mellitus, Non-Insulin-Dependent" OR "Non-Insulin-Dependent Diabetes Mellitus" OR "Diabetes" OR "Diabetes Mellitus, Stable" OR "Stable Diabetes Mellitus" OR "Diabetes Mellitus, Type II" OR "NIDDM" OR "Diabetes Mellitus, Noninsulin Dependent" OR "Diabetes Mellitus, Maturity-Onset" OR "Diabetes Mellitus, Maturity Onset" OR "Maturity-Onset Diabetes Mellitus" OR "Maturity Onset Diabetes Mellitus" OR "MODY" OR "Diabetes Mellitus, Slow-Onset" OR "Type 2 Diabetes Mellitus" OR "Noninsulin-Dependent Diabetes Mellitus" OR "Noninsulin Dependent Diabetes Mellitus" OR "Maturity-Onset " OR "Diabetes, Maturity-Onset" OR "Maturity Onset Diabetes" OR "Type 2 Diabetes" OR "Diabetes, Type 2" OR "Diabetes Mellitus, Noninsulin-Dependent") AND ("decision tree" OR "neural network" OR "Support vector machine" OR "Artificial intelligence" OR "Fuzzy" OR "machine learning" OR "Data mining" OR "genetic algorithm" OR metaheuristic OR "Meta heuristic" OR "meta-heuristic" OR "Cuckoo search" OR "Bees algorithm" OR "Artificial bee colony algorithm" OR "evolutionary algorithm" OR "Ant colony optimization" OR "Particle swarm optimization" OR "Firefly algorithm" OR "Memetic algorithm"))	04/10/1403
Web of Science	Ti=("Diagnoses" OR "Diagnose" OR "Diagnoses and Examinations" OR "Examinations and Diagnoses" OR "Diagnoses and Examination" OR "Examination and Diagnoses" OR "Postmortem Diagnosis" OR "Diagnoses, Postmortem" OR "Diagnosis, Postmortem" OR "Postmortem Diagnoses" OR "Antemortem Diagnosis" OR "Antemortem Diagnoses" OR "Diagnoses, Antemortem" OR "Diagnosis, Antemortem" OR "diagnosis" OR "diagnostic" OR "diagnosing" OR "diagnosed") And Ti =("Adult-Onset Diabetes Mellitus" OR "Ketosis-Resistant Diabetes Mellitus" OR "Diabetes Mellitus, Non Insulin Dependent" OR "Type 2 Diabetes Mellitus" OR "Diabetes Mellitus, Non-Insulin-Dependent" OR "Non-Insulin-Dependent Diabetes Mellitus" OR "Diabetes" OR "Diabetes Mellitus, Stable" OR "Stable Diabetes Mellitus" OR "Diabetes Mellitus, Type II" OR "NIDDM" OR "Diabetes Mellitus, Noninsulin Dependent" OR "Diabetes Mellitus, Maturity-Onset" OR "Diabetes Mellitus, Maturity Onset" OR "Maturity-Onset Diabetes Mellitus" OR "Maturity Onset Diabetes Mellitus" OR "MODY" OR "Diabetes Mellitus, Slow-Onset" OR "Type 2 Diabetes Mellitus" OR "Noninsulin-Dependent Diabetes Mellitus" OR "Noninsulin Dependent Diabetes Mellitus" OR "Maturity-Onset " OR "Diabetes, Maturity-Onset" OR "Maturity Onset Diabetes" OR "Type 2 Diabetes" OR "Diabetes, Type 2" OR "Diabetes Mellitus, Noninsulin-Dependent") And Ti =(" decision tree" OR "neural network" OR "Support vector machine" OR "Artificial intelligence" OR "Fuzzy" OR "machine learning" OR "Data mining" OR "genetic algorithm" OR metaheuristic OR "Meta heuristic" OR "meta-heuristic" OR "Cuckoo search" OR "Bees algorithm" OR "Artificial bee colony algorithm" OR "evolutionary algorithm" OR "Ant colony optimization" OR "Particle swarm optimization" OR "Firefly algorithm" OR "Memetic algorithm")	04/10/1403

داده‌های غیر معتبر یا ناقص بودند، یا روش‌های غیراستاندارد و غیر شناخته شده را به کار برده بودند، از مطالعه خارج شدند. همچنین مقالات کنفرانسی، مقالاتی که متن کامل آنها در دسترس نبود و یا به زبان‌های غیر از انگلیسی منتشر شده از مطالعه حذف شدند. مقالات استخراج شده براساس معیار ورود و خروج مورد بررسی قرار گرفتند ملاک تحلیل شامل نوع الگوریتم مورد استفاده، شاخصهای خروجی و حضور متخصص بالینی در پژوهش بود. جهت بررسی نوع الگوریتم‌ها، ابتدا ساختار و شاخصهای خروجی آنها ارزیابی شدند (نمودار ۱ راهبرد جستجوی مقالات). جهت بررسی عملکرد الگوریتم‌های هوش مصنوعی از شاخص‌های

تمام مقالاتی که بعد از جستجو از پایگاه‌های استنادی استخراج شدند مورد بررسی قرار گرفتند و تعدادی از آنها براساس معیارهای ورود مطالعه انتخاب شدند. بعد از بررسی تمام مقالات استخراج شده از پایگاه‌های استنادی، مقالاتی که با معیارهای ورود مطابقت داشتند انتخاب شدند. معیارهای ورود به مطالعه شامل مقالاتی بودند که به بررسی مدل‌های پیش‌بینی یا تشخیص بیماری دبابه با استفاده از روش‌های هوش مصنوعی پرداخته‌اند، دارای روش‌شناسی معتبر و مبتنی بر الگوریتم‌های شناخته شده هوش مصنوعی بوده‌اند، و در بازه زمانی از ۲۰۰۶ تا ۲۰۲۴ منتشر شده‌اند. همچنین مقالاتی که دارای گزارش نتایج حاصل از ارزیابی مدل باشند و به زبان انگلیسی منتشر شده باشند، انتخاب شد. در مقابل، مقالاتی که فاقد ارتباط مستقیم با موضوع تحقیق بودند، دارای

مختلف شامل دقت^۱، AUC، ویژگی^۲ و حساسیت^۳ استفاده شده است. همچنین برای محاسبه این شاخص‌ها، چهار مقدار اصلی^۴، TP^۴، FN^۷ و TN^۶ به‌عنوان پایه در نظر گرفته شده‌اند (جدول ۳ فرمول‌های محاسبه شاخص‌های ارزیابی).

نمودار ۱- راهبرد جستجوی مقالات



جدول ۳- فرمول‌های محاسبه شاخص‌های ارزیابی

شاخص	فرمول محاسبه
Sensitivity	$\frac{TP}{TP+FN}$
Specificity	$\frac{TN}{FP+TN}$
Accuracy	$\frac{TP+TN}{TP+FN+FP+TN}$

TP: True positive, FN: False negative, TN: True negative,
FP: False positive


تشخیص‌های پیش‌دیابت مورد توجه است پژوهشگران حضور

از آنجا که حضور پزشک جهت تأیید عملکرد الگوریتم‌های


⁵ False Positive
⁶ True Negative
⁷ False Negative

¹ Accuracy
² Specificity
³ Sensitivity
⁴ True Positive

مقالات دو مقدار بالاتر از هر شاخص بر حسب سال در شکل‌های ۲ و ۳ مطرح شده است.



شکل ۲- پراگندگی شاخصهای ارزیابی



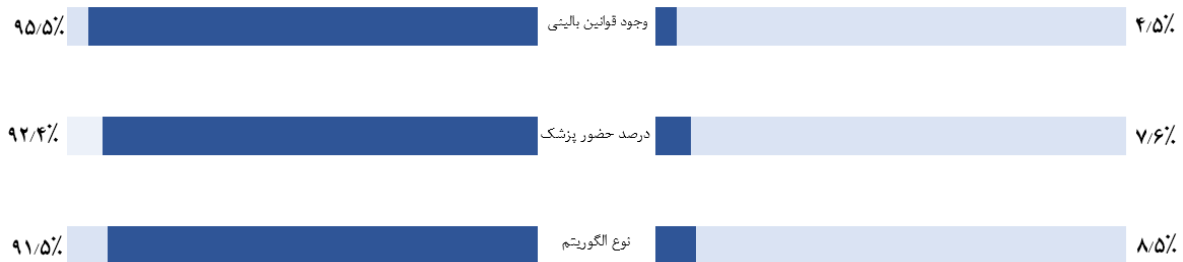
شکل ۳- پراکندگی شاخصهای ارزیابی

پژوهشگران دریافتند که از بین ۲۲۳ مطالعه، ۱۰ مطالعه قانون بالینی استخراج شده است. همچنین در بررسی مقالات مذکور در ۱۷ مقاله از پزشک در تیم تحقیق استفاده شده است. در ۳۶ مقاله الگوریتم‌های مورد استفاده از نوع جعبه سیاه بوده است که شفافیت پایین و عملکرد خوبی دارد و در ۵ مقاله الگوریتم مورد استفاده از نوع جعبه سفید بوده است که خروجی آن بر حسب درصد در شکل ۴ مشاهده می‌شود.

عملکرد الگوریتم‌های هوش مصنوعی در ۲۲۳ مقاله بررسی شد که، در ۱۸۸ مقاله شاخص دقت (Accuracy)، ۴۹ مقاله شاخص AUC، ۵۶ مقاله شاخص ویژگی (Specificity)، ۹۳ مقاله شاخص حساسیت (Sensitivity) مورد ارزیابی قرار گرفت که بازه تغییرات این شاخصها در شکل‌های ۲ و ۳ بیان شده است و ۶ معیارهای آماری (حداقل، حداکثر، میانگین، واریانس، انحراف معیار و دامنه تغییرات) محاسبه و در جدول ۵ گزارش شده است.

جدول ۵- معیارهای ارزیابی

دامنه تغییرات	انحراف معیار	واریانس	میانگین	حداکثر	حداقل	
۳۲/۴۵	۷/۵	۵۷/۴۷	۹۰/۵۳	۱۰۰	۶۷/۵۵	Accuracy
۳۱/۰۹	۷/۱۱	۵۰/۶۳	۸۸/۸۷	۹۹/۶۹	۶۸/۶	AUC
۴۴/۳۵	۹/۰۶	۸۲/۲۲	۸۹/۲۵	۱۰۰	۵۵/۶۵	Specificity
۶۸/۸۳	۱۳/۹۱	۱۹۳/۷	۸۷/۱۲	۱۰۰	۳۱/۱۷	Sensitivity



شکل ۴- نمودار مقایسه‌ای ویژگی‌های مطالعات به‌کاررفته در الگوریتم‌های هوش مصنوعی برای تشخیص پیش‌دیابت

بالینی منتشر نشده است پس از بررسی و مقایسه میزان حساسیت و ویژگی روش‌های مرسوم با روش‌های تشخیص با کمک هوش مصنوعی، نتایج مبین آن بود که به‌طور کلی عملکرد الگوریتم‌های هوش مصنوعی در تشخیص پیش‌دیابت مؤثرتر بوده است که در جدول ۶ آمده است.

در بررسی گایدلاین‌های مورد استفاده جهت تشخیص پیش‌دیابت در Up to date، نتایج مبین آن بود که در روش مرسوم از تست HbA1c و FPG استفاده و حد آستانه برای آن تعیین گردید است [۱۹]. اما در طی بررسی‌های انجام شده در سایت up to date تاکنون برای تشخیص با کمک روش‌های هوش مصنوعی هیچ گایدلاین

جدول ۶- مقایسه حساسیت و ویژگی پیش‌دیابت در هوش مصنوعی و دو گایدلاین بالینی

نام روش	حساسیت	ویژگی
HbA1c	۶۰/۶٪	۷۲/۱٪
FPG	۸۹٪	۹۲/۸٪
AI	۱۰۰٪	۱۰۰٪

HbA1c: Glycated hemoglobin, FPG: Fasting plasma glucose, AI: Artificial intelligence

بحث

مؤثر اثر بخشی در ارزیابی و استفاده از مدل ارائه شده مورد توجه قرار داد. یکی از موارد اصلی کاربرد الگوریتم‌های تشخیص بیماری دیابت، پیش‌بینی بیماران پیش‌دیابت است. زیرا شناسایی افرادی در معرض خطر بالایی برای ابتلا به دیابت و مداخله و درمان مناسب می‌تواند از تشدید بیماری جلوگیری می‌کند [۱۳، ۸]. استفاده از روش‌های هوش مصنوعی به‌جای روش‌های مرسوم مانند اندازه‌گیری سطح HbA1c و FPG می‌تواند در تشخیص بیماری پیش‌دیابت کمک شایانی کند؛ اما امروزه به‌دلیل محدودیت‌های روش‌های هوش مصنوعی استفاده از الگوریتم‌ها در بالین به‌صورت عملی استفاده نمی‌شود. در بررسی مقالات مشابه، نتایج مبین آن بود که در مقالات به ارزیابی‌های بالینی، حضور پزشک در مطالعه، نوع الگوریتم‌ها و میزان کارایی الگوریتم در پیش‌بینی پیش‌دیابت توجه نشده است.

با بررسی‌های انجام شده در ۲۲۳ مقاله در زمینه استفاده از یادگیری ماشین در تشخیص دیابت نتایج مبین آن بود که الگوریتم RF پُرکارترین الگوریتم است. این الگوریتم قادر به تشخیص الگوها و

هدف از این مطالعه، مروری بر مطالعاتی است که در زمینه استفاده از یادگیری ماشین در تشخیص دیابت است تا بتوان میزان اثربخشی یادگیری ماشین را در تشخیص و پیش‌بینی دیابت مورد ارزیابی قرار داد. استفاده از هوش مصنوعی در علم پزشکی می‌تواند به‌صورت مفید تلقی شود، زیرا در تشخیص بیماری‌ها، درمان بیمار، کاهش خطاها و ارائه پشتیبانی از بیمار کمک می‌کند. و از طرفی هم می‌تواند چالش‌ها و نگرانی‌هایی را هم ایجاد کند. ممکن است خروجی الگوریتم‌های هوش مصنوعی در تشخیص دیابت از نظر شاخصهای ارزیابی عملکرد مناسبی داشته باشد اما در صورت عدم حضور پزشک در تیم تحقیق و عدم استفاده از نظر پزشک متخصص، عدم ارزیابی بالینی قوانین استخراج شد از الگوریتم‌ها می‌تواند خطاهایی را ایجاد و عملیاتی شدن مدل را تحت تأثیر قرار بدهد. همچنین نوع الگوریتم مورد استفاده (از لحاظ جعبه سیاه یا سفید) نیز می‌تواند در ارائه قوانین بالینی تأثیر گذار باشد که باید به آن به‌عنوان یکی از عوامل

روابط پیچیده در داده‌های پزشکی است و می‌تواند داده‌های بزرگ و پیچیده را پردازش نماید و از آنجا که در پزشکی، حجم داده‌ها و اطلاعات بالا است، استفاده از این الگوریتم‌ها می‌تواند به بهبود تحلیل داده‌ها و ارائه پیش‌بینی‌های دقیق‌تر کمک کند. به همین علت از این الگوریتم در پژوهش تشخیص دیابت بیشتر استفاده گردید ولی نقطه ضعف اصلی این الگوریتم در بالین مورد توجه قرار نگرفته است RF معمولاً به‌عنوان مدل پیچیده شناخته شده است. الگوریتم RF یکی از الگوریتم‌های جعبه سیاه است الگوریتم‌های جعبه سیاه معمولاً مدل‌های پیچیده یادگیری ماشینی هستند که عملکرد درونی آنها به‌راحتی توسط انسان قابل تفسیر نیست و دارای عملکرد بالا و شفافیت پایین است به همین دلیل در بالین قابل استفاده نیست که در ۸۸ درصد از مقالات مورد بررسی، از این الگوریتم‌ها استفاده شده است. در مطالعه Sharma و همکاران [۱۵] نتایج مبین آن بود که مدل‌های یادگیری عمیق، از شبکه‌های عصبی مصنوعی تا شبکه‌های عصبی بازگشتی، توانایی بازده بیشتری در پیش‌بینی بیماری با دقت بیشتر دارند. در این پژوهش ارزیابی‌های بالینی انجام نشده و به نوع الگوریتم‌ها نیز توجهی نشده است. در صورتی که در مطالعه حاضر به تمامی این موارد پرداخته شده است.

شاخص دیگری که در این مقالات مورد بررسی قرار گرفت حضور حداقل یک متخصص بالینی در مقالات پیش‌بینی ابتلا به بیماری دیابت است زیرا پزشکان نقش مهمی در ارزیابی‌های بالینی هوش مصنوعی 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 فرآیند ارزیابی وارد می‌کنند [۲۱]. در مرحله پیش‌پردازش داده‌ها، نقش پزشک حیاتی است، زیرا کیفیت داده‌های ورودی تأثیر مستقیمی بر عملکرد مدل‌های تشخیصی هوش مصنوعی دارد. پزشک در انتخاب و تأیید متغیرهای کلیدی نقش دارد تا اطمینان حاصل شود که ویژگی‌های مهم بالینی، آزمایشگاهی یا تصویربرداری به درستی در مدل گنجانده شده‌اند [۲۲]. همچنین، او با شناسایی و حذف داده‌های نادرست، ناسازگار یا نویزدار از کاهش دقت مدل جلوگیری می‌کند [۲۳]. برچسب‌گذاری صحیح داده‌ها یکی دیگر از وظایف پزشک است که در مدل‌های یادگیری نظارت‌شده اهمیت ویژه‌ای دارد. علاوه بر این، پزشک بر کنترل کیفیت داده‌ها نظارت دارد و اطمینان حاصل می‌کند که اطلاعات ورودی از نظر بالینی منطقی و بدون خطا هستند [۲۴]. 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

رابطه پزشک و بیمار تأثیر منفی نمی‌گذارند [۲۵]. همچنین نقش پزشک در اعتبارسنجی خروجی مدل و تفسیر نتایج تشخیصی اهمیت دارد؛ به‌عنوان مثال، او می‌تواند بررسی کند که آیا پیش‌بینی‌های مدل با معیارهای بالینی همخوانی دارند و در صورت نیاز، اصلاحات لازم را در طراحی مدل یا نحوه استفاده از آن پیشنهاد دهد. به‌طور کلی، پزشک به‌عنوان یک ناظر متخصص در کنار پژوهشگران هوش مصنوعی، به بهبود دقت، قابلیت اطمینان و کارایی مدل‌های تشخیصی کمک می‌کند [۲۶]. در بررسی مقالات نتایج بیان‌کننده آن بود که تنها در ۲ درصد از مقالات پزشک در تیم پژوهشی حضور داشته است که نشان دهنده ضعف در تحقیقات است، لذا توصیه می‌شود حتماً حداقل یک متخصص پزشک در پژوهش حضور داشته باشد. در مطالعه Guan و همکاران نیز به حضور پزشک در تیم تحقیق اشاره شده است اما در مطالعه به توانایی و یا کیفیت تشخیص بیماری پیش‌دیابت توجهی نشده است [۱۴].

شاخص‌های ارزیابی هوش مصنوعی به جهت تضمین ایمنی و تأثیر ابزارهای هوش مصنوعی در بهبود عملکرد بالینی در بالین از اهمیت حیاتی برخوردار هستند [۲۷]. در حالی که هوش مصنوعی در بهبود تشخیص و مراقبت از بیمار مؤثر است، چالش‌هایی مانند سوگیری الگوریتمی، حریم خصوصی داده‌ها، و ماهیت «جعبه سیاه» برخی از مدل‌های هوش مصنوعی، تناقضات بالقوه‌ای را با کارایی و قابل اعتماد بودن آنها در عمل بالینی نشان می‌دهد [۲۸]. هوش مصنوعی، به‌ویژه یادگیری ماشینی، اغلب با توانایی آن در تشخیص الگوها و روابط پیچیده در داده‌ها مشخص می‌شود که ممکن است به آسانی برای رویکردهای آماری مرسوم آشکار یا قابل دسترسی نباشد [۲۹، ۳۰]. در مقالات مورد بررسی ۴ شاخص ارزیابی مورد بررسی قرار گرفته است که شاخص صحت Accuracy در بازه ۷۷/۵۵-۱۰۰، شاخص AUC در بازه ۶۷/۶-۹۹/۶۹، شاخص Specificity در بازه ۵۵/۶۵-۱۰۰ و شاخص Sensitivity در بازه ۳۱/۱۷-۱۰۰ گزارش شده است. در مطالعه Chaki و همکاران [۱۶] نتایج مبین آن بود که در برخی از آنها به دقت بالا، AUC و سایر معیارهای عملکرد دست یافتند. اما به‌طور کلی نتایج بیان‌کننده آن بود که، الگوریتم درخت تصمیم نتایج بهتری را نشان داد و به دقت ۹۰/۰۴ درصد در تشخیص دیابت نوع دو دست یافت. اما در این مطالعه مواردی از قبیل ارزیابی‌های بالینی و نوع الگوریتم‌های مورد استفاده، تجزیه و تحلیل نشده است و به حضور پزشک در تیم پژوهش نیز توجهی نشده و همچنین به بررسی تشخیص بیماران پیش‌دیابت نیز پرداخته نشده است.

ارزیابی بالینی یک روش مهم است که باید حتماً قوانین به دست آمده یک روش برای تشخیص و یا درمان باید از طریق روش‌های

روابط پیچیده در داده‌های پزشکی است و می‌تواند داده‌های بزرگ و پیچیده را پردازش نماید و از آنجا که در پزشکی، حجم داده‌ها و اطلاعات بالا است، استفاده از این الگوریتم‌ها می‌تواند به بهبود تحلیل داده‌ها و ارائه پیش‌بینی‌های دقیق‌تر کمک کند. به همین علت از این الگوریتم در پژوهش تشخیص دیابت بیشتر استفاده گردید ولی نقطه ضعف اصلی این الگوریتم در بالین مورد توجه قرار نگرفته است RF معمولاً به‌عنوان مدل پیچیده شناخته شده است. الگوریتم RF یکی از الگوریتم‌های جعبه سیاه است الگوریتم‌های جعبه سیاه معمولاً مدل‌های پیچیده یادگیری ماشینی هستند که عملکرد درونی آنها به‌راحتی توسط انسان قابل تفسیر نیست و دارای عملکرد بالا و شفافیت پایین است به همین دلیل در بالین قابل استفاده نیست که در ۸۸ درصد از مقالات مورد بررسی، از این الگوریتم‌ها استفاده شده است. در مطالعه Sharma و همکاران [۱۵] نتایج مبین آن بود که مدل‌های یادگیری عمیق، از شبکه‌های عصبی مصنوعی تا شبکه‌های عصبی بازگشتی، توانایی بازده بیشتری در پیش‌بینی بیماری با دقت بیشتر دارند. در این پژوهش ارزیابی‌های بالینی انجام نشده و به نوع الگوریتم‌ها نیز توجهی نشده است. در صورتی که در مطالعه حاضر به تمامی این موارد پرداخته شده است.

شاخص دیگری که در این مقالات مورد بررسی قرار گرفت حضور حداقل یک متخصص بالینی در مقالات پیش‌بینی ابتلا به بیماری دیابت است زیرا پزشکان نقش مهمی در ارزیابی‌های بالینی هوش مصنوعی 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 فرآیند ارزیابی وارد می‌کنند [۲۱]. در مرحله پیش‌پردازش داده‌ها، نقش پزشک حیاتی است، زیرا کیفیت داده‌های ورودی تأثیر مستقیمی بر عملکرد مدل‌های تشخیصی هوش مصنوعی دارد. پزشک در انتخاب و تأیید متغیرهای کلیدی نقش دارد تا اطمینان حاصل شود که ویژگی‌های مهم بالینی، آزمایشگاهی یا تصویربرداری به درستی در مدل گنجانده شده‌اند [۲۲]. همچنین، او با شناسایی و حذف داده‌های نادرست، ناسازگار یا نویزدار از کاهش دقت مدل جلوگیری می‌کند [۲۳]. برچسب‌گذاری صحیح داده‌ها یکی دیگر از وظایف پزشک است که در مدل‌های یادگیری نظارت‌شده اهمیت ویژه‌ای دارد. علاوه بر این، پزشک بر کنترل کیفیت داده‌ها نظارت دارد و اطمینان حاصل می‌کند که اطلاعات ورودی از نظر بالینی منطقی و بدون خطا هستند [۲۴]. 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

در صورتی که این قوانین در مطالعات بالینی معتبر تأیید شوند، می‌توانند در گایدلاین‌های تشخیصی ادغام شده و به‌عنوان ابزار کمکی در کنار روش‌های استاندارد مورد استفاده قرار گیرند. چنین رویکردی نه تنها باعث بهبود دقت و کارایی غربالگری دیابت می‌شود، بلکه به افزایش اعتماد و پذیرش این فناوری در محیط‌های بالینی کمک خواهد کرد [۳۷].

نتایج کلی این مطالعه مبین آن بود که عملکرد هوش مصنوعی در تشخیص پیش‌دیابت به‌طور قابل‌توجهی بهتر از روش‌های مرسوم است، اما از آنجا که بسیاری از این الگوریتم‌ها قابل ارزیابی بالینی نبوده‌اند، متخصصین در تیم‌های پژوهشی حضور نداشته‌اند، و روش‌های مورد استفاده عمدتاً جعبه سیاه (Black Box) بوده‌اند، هنوز قابلیت استفاده‌ی بالینی ندارند. چنانچه این محدودیت‌ها برطرف شوند، هوش مصنوعی می‌تواند به‌عنوان یک روش نوین با عملکرد بهتر در تشخیص پیش‌دیابت مورد استفاده قرار گیرد.

محدودیت‌ها

الگوریتم‌ها را به‌صورت کلی مورد بررسی قرار داده و بر روی جزئیات الگوریتم‌ها مطالعه انجام نشده است. حجم نمونه‌ها را مورد بررسی قرار نداده زیرا بیشتر بر روی کاربردپذیر بودن الگوریتم در بالین، ارزیابی قوانین بالینی و حضور پزشک و نوع الگوریتم تمرکز کرده ایم.

کارهای آینده

پیشنهاد می‌گردد در کارهای آینده نقاط ضعف و قوت الگوریتم جعبه سفید نیز مورد بررسی قرار بگیرد. در صورت استخراج قانون بالینی با کمک الگوریتم‌ها هزینه آنان را مورد بررسی قرار داده و امکان‌سنجی آن را نیز بررسی کنیم.

تعارض منافع

نویسندگان اعلام می‌دارند که هیچ‌گونه تضاد منافی در پژوهش حاضر وجود ندارد.

سپاسگزاری

بدین‌وسیله از معاونت پژوهشی دانشگاه علوم پزشکی شاهرود به‌دلیل حمایت‌های ارزشمند علمی و پژوهشی در فرایند انجام این مطالعه صمیمانه قدردانی می‌شود. پشتیبانی‌های این معاونت نقش مهمی در تسهیل مراحل اجرا، تحلیل و تکمیل این پژوهش داشته است.

مرسوم بالینی مانند دلفی و فکوسگروپ و... ارزیابی شود [۱۷، ۱۸]. جهت تشخیص بیماری پیش‌دیابت، پزشکان معمولاً از بررسی شاخص‌های HbA1c و FPG استفاده می‌کنند. در مطالعه Vera و همکاران، حد آستانه HbA1c برای پیش‌دیابت ۵/۵ درصد، با حساسیت ۶۰/۵ درصد و ویژگی ۶۳/۱ درصد تعیین شد [۳۱]. در مطالعه Shimodaira و همکاران، حد آستانه HbA1c برای پیش‌دیابت ۵/۷٪، با حساسیت ۶۰/۶٪ و ویژگی ۷۲/۱٪ مشخص شد، اگرچه دقت آن پایین گزارش شده بود [۱۱]. در مطالعه دیگری، نشان داده شد FPG حساسیت بالا (۸۹/۰٪) و ویژگی (۹۲/۸٪) برای تشخیص دیابت دارد، که ممکن است حاکی از عملکرد معقول برای تشخیص پیش‌دیابت باشد [۳۲]. با این حال، تشخیص زودهنگام پیش‌دیابت با چالش‌های متعددی مواجه است، از جمله نوسانات سطح گلوکز، تأثیر متغیرهای فردی و محیطی، و محدودیت روش‌های رایج مانند HbA1c و FPG. این روش‌ها اغلب حساسیت و ویژگی کافی برای شناسایی دقیق افراد در معرض خطر را ندارند و ممکن است مواردی از پیش‌دیابت را در مراحل اولیه شناسایی نکنند [۳۳].

هوش مصنوعی با بهره‌گیری از الگوریتم‌های یادگیری ماشین و تحلیل داده‌های گسترده بالینی، می‌تواند الگوهای پنهان مرتبط با پیش‌دیابت را شناسایی کرده و مدل‌های پیش‌بینی شخصی‌سازی‌شده ارائه دهد. این مدل‌ها با ترکیب متغیرهای مختلف مانند ویژگی‌های ژنتیکی، سبک زندگی، داده‌های تغذیه‌ای و نتایج آزمایشگاهی، قادرند خطر ابتلا به دیابت را دقیق‌تر ارزیابی کنند. علاوه بر این، هوش مصنوعی می‌تواند از داده‌های طولی و الگوهای تغییرات در طول زمان برای ارائه هشدارهای زودهنگام استفاده کرده و امکان مداخلات پیشگیرانه مؤثرتر را فراهم کند [۳۴].

با این وجود، یکی از موانع اصلی در پذیرش بالینی الگوریتم‌های هوش مصنوعی، شفافیت پایین مدل‌های جعبه سیاه (Black Box) است که منجر به عدم اعتماد پزشکان و بیماران به تصمیمات آنها می‌شود. این مدل‌ها اغلب دارای فرآیندهای پردازشی پیچیده و غیرقابل توضیح هستند که درک منطق پیش‌بینی‌ها و تصمیم‌گیری‌های آنها را دشوار می‌سازد. برای بهبود این وضعیت، روش‌هایی مانند توسعه مدل‌های تفسیرپذیرتر (مانند درخت‌های تصمیم و شبکه‌های بیزین)، استفاده از تکنیک‌های توضیح‌پذیری مانند SHAP و LIME، و ترکیب داده‌های پزشکی با دانش متخصصان پیشنهاد شده‌اند [۳۵].

علاوه بر این، قوانین استخراج‌شده از الگوریتم‌های هوش مصنوعی باید از نظر هزینه، کارایی و امکان‌سنجی عملی ارزیابی شوند.

References

1. Yapıslar H, Gurler EB. Management of Microcomplications of Diabetes Mellitus: Challenges, Current Trends, and Future Perspectives in Treatment. *Biomedicines*. 2024; 12(9):1958.
2. Paneni F, Cosentino F, Paneni F, Cosentino F. *Epidemiology, definition, and diagnosis of diabetes mellitus*. Springer; 2015.
3. Phillips A, Mehl AA. Diabetes mellitus and the increased risk of foot injuries. *J Wound Care*. 2015 May;24(5 Suppl 2):4-7.
4. Hussain A. Raising awareness and improving diabetes care to reduce the impact of complications. *Diabetes Res Clin Pract*. 2023; 205:110968.
5. Revika SP, Yahfizham YJSJTI, Sains dan Ilmu Komunikasi. Studi Literatur Analisis Algoritma Pemrograman Pengaruh Computational Thinking pada Pembelajaran Matematika. *SABER: Jurnal Teknik Informatika, Sains Dan Ilmu Komunikasi*. 2023; 2(1), 17–29.
6. Cenikj G, Petelin G, Doerr C, Korošec P, Eftimov T, editors. Dynamorep: trajectory-based population dynamics for classification of black-box optimization problems. *Proceedings of the Genetic and Evolutionary Computation Conference*; 2023.
7. Sahin OJASC. Generation of black-box adversarial attacks using many independent objective-based algorithm for testing the robustness of deep neural networks. *Applied Soft Computing*. 2024; 164:111969.
8. Torres-Salvador PD, Malaza GG, & Mercado-Asis, LB. Correlation of Glycosylated Hemoglobin And Oral Glucose Tolerance Test Results In Hyperinsulinemic Pre-Impaired Glucose Tolerance State Versus Normoinsulinemic-Normal OGTT. *Journal of Medicine, University of Santo Tomas*. 2018; 2(1), 155–159.
9. Inzucchi SE. *Clinical presentation, diagnosis, and initial evaluation of diabetes mellitus in adults*. 2021; Available from: https://www.uptodate.com/contents/search?search=prediabetes%20diagnosis&sp=0&searchType=PLAIN_TEXT&source=USER_INPUT&autoComplete=true.
10. Jones D, Scharfenberg B, Perkins J, Childers K, Dogbey GY, Shubrook JH. Glycated Hemoglobin Testing to Identify Undiagnosed Diabetes Mellitus in the Inpatient Setting. *J Am Osteopath Assoc*. 2016; 116(6):350-7.
11. Shimodaira M, Okaniwa S, Hanyu N, Nakayama T. Optimal Hemoglobin A1c Levels for Screening of Diabetes and Prediabetes in the Japanese Population. *J Diabetes Res*. 2015; 2015:932057.
12. White KAM, Daneshvari S, Lilyquist J, Luo L, Steffen LE, Bivin A, Gurule N, Ducasa GM, Torres SM, Lindeman R, Sankarappan S, Berwick M. Prediabetes: The Variation between HbA1c and Fasting Plasma Glucose. *Int J Diabetol Vasc Dis Res*. 2015; Suppl 2:001.
13. Aekplakorn W, Tantayotai V, Numsangkul S, Sripho W, Tatsato N, Burapasiriwat T, Pipatsart R, Sansom P, Luckanajantachote P, Chawarokorn P, Thanonghan A, Lakhankaw W, Mungkung A, Boonkean R, Chantapoon C, Kungsri M, Luanseng K, Chaiyajit K. Detecting Prediabetes and Diabetes: Agreement between Fasting Plasma Glucose and Oral Glucose Tolerance Test in Thai Adults. *J Diabetes Res*. 2015; 2015:396505.
14. Guan Z, Li H, Liu R, Cai C, Liu Y, Li J, Wang X, Huang S, Wu L, Liu D, Yu S, Wang Z, Shu J, Hou X, Yang X, Jia W, Sheng B. Artificial intelligence in diabetes management: Advancements, opportunities, and challenges. *Cell Rep Med*. 2023; 17;4(10):101213..
15. Sharma T, Shah MA. Comprehensive review of machine learning techniques on diabetes detection. *Vis. Comput. Ind. Biomed. Art*. 2021; 4, 30.
16. Chaki Jy, Ganesh ST, Cidham SK, Theertan SA. Machine learning and artificial intelligence based Diabetes Mellitus detection and self-management: A systematic review. *Journal of King Saud University - Computer and Information Sciences*. 2022; 34(6):3204-25.
17. Cuhls K. *The Delphi method: an introduction. Delphi methods in the social and health sciences: concepts, applications and case studies*: Springer; 2023; p. 3-27.
18. Gundumogula MGM. Importance of Focus Groups in Qualitative Research. *International Journal of Humanities and Social Science (IJHSS)*. 2020; 8(11):299-302.
19. Hayward RA, Selvin E. *Screening for type 2 diabetes mellitus*. 2024; Available from: https://www.uptodate.com/contents/screening-for-type-2-diabetes-mellitus-and-prediabetes?search=prediabetes%20hba1c%20&source=search_result&selectedTitle=1~150&usage_type=default&display_rank=1
20. Robertson RP. *Prevention of type 2 diabetes mellitus*. 2024; Available from: <https://www.uptodate.com/contents/prevention-of-type-2-diabetes-mellitus>
21. Magrabi F, Ammenwerth E, McNair JB, De Keizer NF, Hyppönen H, Nykänen P, Rigby M, Scott PJ, Vehko T, Wong ZS, Georgiou A. Artificial Intelligence in Clinical Decision Support: Challenges for Evaluating AI and Practical Implications. *Yearb Med Inform*. 2019; 28(1):128-134.
22. Chahid I, Elmiad AK, Badaoui M, editors. Data Preprocessing For Machine Learning Applications in Healthcare: A Review. 2023; *14th International Conference on Intelligent Systems: Theories and Applications (SITA)*; 2023: IEEE.
23. Enshaei N, Naderkhani FJIRM. The Role of Data Quality for Reliable AI Performance in Medical Applications. *IEEE Reliability Magazine*. 2024; 1(3):24-28,
24. Krüger F, editor Keynote: Adventures in Annotation: Providing High Quality Labels for Supervised Machine Learning. 2022; *IEEE International Conference on Pervasive Computing and Communications Workshops and other Affiliated Events (PerCom Workshops)*; 2022: IEEE.
25. Durosini I, Pizzoli SFM, Strika M, Pravettoni G. *Chapter 16 - Artificial intelligence and medicine: A psychological perspective on AI implementation in healthcare context*, Editor(s): Shai Ben-David, Giuseppe Curigliano, David Koff, Barbara Alicja Jereczek-Fossa, Davide La Torre, Gabriella Pravettoni, In *Advanced Studies in Complex Systems: Theory and Applications*, Artificial

- Intelligence for Medicine, Academic Press; 2024; 231-7.
26. Abbasian Ardakani A, Airom O, Khorshidi H, Bureau NJ, Salvi M, Molinari F, Acharya UR. Interpretation of Artificial Intelligence Models in Healthcare: A Pictorial Guide for Clinicians. *J Ultrasound Med.* 2024; 43(10):1789-1818.
 27. 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):629-639.
 28. Lainjo B. A meta-study on optimizing healthcare performance with artificial intelligence and machine learning. *Journal of Autonomous Intelligence.* 2024; 7(5):1-23.
 29. Handelman GS, Kok HK, Chandra RV, Razavi AH, Huang S, Brooks M, Lee MJ, Asadi H. Peering Into the Black Box of Artificial Intelligence: Evaluation Metrics of Machine Learning Methods. *AJR Am J Roentgenol.* 2019; 212(1):38-43.
 30. Martha S, Warangal T, Priya IMN. Role Of Statistics In Artificial Intelligence. *International Journal of Engineering Applied Sciences and Technology.* 2022; 7(12):96-98.
 31. Vera-Ponce VJ, Zuzunaga-Montoya FE, Loayza-Castro JA, Vasquez-Romero LEM, Paucar CRI, Valladares-Garrido MJ, et al. Concordance and Associated Factors in Diagnostic Criteria for Prediabetes and Diabetes: An Analysis of Fasting Glucose, Postprandial Glucose, and Glycated Hemoglobin. *Journal of Endocrinology and Metabolism.* 2024; 14(1):48-58.
 32. YU C, GE J, LI J, Meng J, Liu W, Liu JJCJoE, et al. Diagnostic value of HbA1c and fasting plasma glucose as early screening parameters for diabetes mellitus. *Chinese Journal of Endocrinology and Metabolism.* 2011:390-2.
 33. Pavithra S, Ravikumar S, Sreesubha S, Babu R, Kalaiselvi M, editors. Early Diagnosis of Diabetes and Prediction Using Machine Learning Algorithm. 2024; *Second International Conference on Intelligent Cyber Physical Systems and Internet of Things (ICoICI), Coimbatore, India, 2024*; p, 1457-1462,
 34. Jain J, Sruthi G, Karuppanan P, editors. Investigation of Diabetes Prediction Using Machine Learning Algorithms. 2024; *IEEE Students Conference on Engineering and Systems (SCES), Prayagraj, India, 2024*; p, 1-6
 35. Adeniran AA, Onebunne AP, William P. Explainable AI (XAI) in healthcare: Enhancing trust and transparency in critical decision-making. *World Journal of Advanced Research and Reviews.* 2024; 23(03):2647–2658.
 36. Inukonda J, Rajasekhara Reddy Tetala V, Hallur JJIJFMR. Explainable Artificial Intelligence (XAI) in Healthcare: Enhancing Transparency and Trust. *International Journal for Multidisciplinary Research (IJFMR).* 2024; (6)6:1-10.
 37. Zhang Z, Lu Y, Ye M, Huang W, Jin L, Zhang G, et al. A novel evolutionary ensemble prediction model using harmony search and stacking for diabetes diagnosis. *Journal of King Saud University - Computer and Information Sciences. Journal of King Saud University - Computer and Information Sciences.* 2024; 36(1):101873

پیوست ۱

بودن آن، حضور یا عدم حضور پزشک در تیم تحقیق جهت بررسی روند کار، بررسی ارزیابی بالینی و همچنین بررسی شاخص‌ها جهت مقایسه عملکرد الگوریتم‌ها است.

جدول زیر جدول مقایسه متغیرهای مورد استفاده در مطالعه است که شامل نوع الگوریتم مورد استفاده و جعبه سیاه یا سفید

جدول بررسی مقالات

ردیف	الگوریتم	نوع الگوریتم	پزشک متخصص شرکت داشته یا خیر؟	ارزیابی	قوانین بالینی
(1)	T2FNN	Black Box	NO	Sensitivity= 99.25%	NO
(2)	ANN	Black Box	NO	Accuracy = 78.65%	NO
(3)	ANN	Black Box	NO	Accuracy =86% AUC=93.4%*	NO
(4)	XGBoost	Black Box	NO	Accuracy =99.4% F1=0.99 AUC=99%	NO
(5)	SVM Random Forest Gradient Boosting	Black Box Black Box Black Box	NO	Accuracy=85% Sensitivity=88.5% Specificity=84.7% F1=38.0%	NO
(6)	Decision Tree	Black Box	YES	Sensitivity=100% Specificity=80.66%	NO
(7)	ANN	Black Box	NO	Accuracy=90%	NO
(8)	ANN	Black Box	NO	Accuracy=77.5% Sensitivity =66.7% F-Measure=74.3%	NO
(9)	Random Forest	Black Box	NO	Accuracy = 97.3%	NO
(10)	RNN	Black Box	YES	F1=97.3 %	NO
(11)	Random Forest	Black Box	NO	Accuracy=98.95% F1-Score=99%	NO
(12)	ANN	Black Box	YES	AUC = 82.7%	YES
(13)	Fuzzy Inference System	Black Box	NO	Accuracy=86.84% Sensitivity=69.54%	YES
(14)	Random Forest	Black Box	YES	Accuracy=98.73% Sensitivity=98.01%	NO
(15)	T2-FNN (type-2 fuzzy system - neural networks)	Black Box	NO	Accuracy=99.06% Sensitivity=99.24% Specificity=99.00%	YES
(16)	ANN	Black Box	NO	Accuracy = 78.57%	NO
(17)	ACO	Black Box	NO	Accuracy=67.55%	YES
(18)	SVM	Black Box	NO	Accuracy=91.87% Sensitivity=94.15% Specificity=89.16% F-Measure= 88.57%	NO
(19)	RBFNN	Black Box	NO	Accuracy=98.4% Sensitivity=99.1% Specificity=94.3%	YES

				F1 Score= 99%	
(20)	SVM	Black Box	YES	Accuracy=94% Sensitivity=93% Specificity=94%	YES
(21)	Logistic Regression	white Box	NO	Accuracy=77% Precision=77% Sensitivity =77% F-Score= 76% AUC=83%	NO
(22)	Fuzzy Decision Tree	Black Box	NO	Accuracy=91.67%	YES
(23)	SB-SVM	Black Box	NO	AUC = 97.15%	NO
(24)	XGBoost	Black Box	NO	AUC=84%	NO
(25)	Gradient Boosting	Black Box	NO	Accuracy=86%	NO
(26)	ANN	Black Box	YES	AUC=84.1%	NO
(27)	SVM	Black Box	YES	Accuracy=87% Sensitivity =93.3% Specificity =74%	NO
(28)	LDA MWSVM	Black Box	NO	Accuracy=89.74%	NO
(29)	Decision Tree	Black Box	NO	Accuracy=93.75%	NO
(30)	Random Forest	Black Box	NO	Accuracy=76%	NO
(31)	SVM	Black Box	NO	Accuracy=75%	yes
(32)	ANN	Black Box	NO	Accuracy=98.1% AUC=98.3% Sensitivity=98.4% Specificity=97.5%	NO
(33)	SVM-RBF	Black Box	NO	Accuracy = 97.14%	NO
(34)	SVM	Black Box	NO	Accuracy =100%	NO
(35)	Optimised-ANFIS	Black Box	NO	Accuracy =80.47%	NO
(36)	K-means J48	Black Box	NO	Accuracy = 90.04% Sensitivity=87.27% Specificity=91.28%	NO
(37)	MAIRS2	Black Box	NO	Accuracy = 89.10% Sensitivity=85.18% Specificity=91.50%	NO
(38)	Logistic Regression	white Box	NO	Accuracy =77.61% Sensitivity=89.02 %	NO
(39)	DNN	Black Box	NO	Accuracy=99.5% Sensitivity=98.48% Specificity=100%	NO
(40)	Random Forest	Black Box	NO	Sensitivity =90.4% Precision =68%	NO
(41)	SVM	Black Box	NO	Accuracy=78.9% AUC= 86.9%	NO
(42)	Random Forest KNN	Black Box Black Box	NO	Accuracy=98.59%	NO
(43)	ANN	Black Box	NO	Accuracy=93.8% ROC-AUC=96%	NO

(44)	Random Forest	Black Box	NO	sensitivity = 98% AUC=97%	NO
(45)	Stacking	Black Box	NO	sensitivity = 73% AUC= 79.8%	NO
(46)	Random Forest	Black Box	NO	Accuracy = 80.5%	NO
(47)	GRU LSTM	Black Box	NO	Accuracy = 98%	NO
(48)	Fuzzy System	Black Box	NO	Accuracy=87.95%	NO
(49)	Fuzzy System	Black Box	NO	Accuracy=75.1% Sensitivity=73.39% Specificity=78.4%	NO
(50)	ANN	Black Box	NO	Accuracy=97.2% Sensitivity=97.8% Specificity=96.6%	NO
(51)	SW-FFANN	Black Box	NO	Accuracy= 91.66% Sensitivity= 85% Specificity= 96.15%	NO
(52)	J48	Black Box	NO	Sensitivity = 95.2%	NO
(53)	SVM	Black Box	NO	Accuracy= 97.87% Sensitivity =100% Specificity =95.45%	NO
(54)	ANFIS	Black Box	yes	Accuracy = 94.5%	NO
(55)	FFANN	Black Box	NO	Accuracy =96.53% Sensitivity = 93.28% F1 Score= 94.88%	NO
(56)	Bagging	Black Box	NO	Accuracy= 95.56% F1-Score= 95.6% AUC-ROC= 95.5% Sensitivity = 96.3%	NO
(57)	Logistic Regression	white Box	NO	Accuracy= 77.6% Sensitivity = 76% F1= 75%	NO
(58)	Gradient Boosting	Black Box	NO	Accuracy= 97.24%	NO
(59)	FCS-ANTMINER	Black Box	NO	Accuracy= 84.24%	NO
(60)	Random Forest	Black Box	yes	Accuracy= 90.43%	NO
(61)	XGBoost	Black Box	NO	Accuracy= 94.5%	NO
(62)	RBFNN	Black Box	NO	Accuracy= 79.8%	NO
(63)	Random Forest	Black Box	NO	Accuracy= 98.71%	NO
(64)	Random Forest	Black Box	NO	Accuracy= 98%	NO
(65)	Ensemble	Black Box	NO	Accuracy= 77.6%	NO
(66)	Fuzzy System	Black Box	NO	Accuracy= 90.3%	NO
(67)	SVM	Black Box	NO	Accuracy= 97.55%	NO
(68)	Decision Tree	Black Box	NO	Accuracy=71.7% ROC=87.5%	NO
(69)	Random Forest	Black Box	yes	ROC=88.3%	NO

(70)	Random Forest	Black Box	yes	ROC=88.3	NO
(71)	XGBoost	Black Box	NO	ROC=78.74%	NO
(72)	SVM BRF	Black Box Black Box	NO	Accuracy=94.92% Sensitivity=92.98%	NO
(73)	CNN SVM	Black Box Black Box	NO	Accuracy=88.21% Sensitivity =89.9%	NO
(74)	SVM	Black Box	NO	Accuracy=96.35%	NO
(75)	ANN	Black Box	NO	Accuracy=97.18%	NO
(76)	ANN	Black Box	NO	Accuracy=97.44%	NO
(77)	LightGBM	Black Box	NO	Accuracy=90% AUC =94.8%	NO
(78)	SVM Random Forest	Black Box Black Box	NO	Accuracy=88%	NO
(79)	DNN	Black Box	NO	Accuracy=90.26%	NO
(80)	HPM provided	Black Box	NO	Accuracy=92.55% Sensitivity=93.40% Specificity=91.74%	NO
(81)	extra trees classifier	Black Box	NO	Accurac=97.33%	NO
(82)	Random Forest	Black Box	NO	Accuracy=81.01% Sensitivity=79.5% AUC= 87/1%	NO
(83)	HBGB	Black Box	NO	Accuracy=92.2%	NO
(84)	ANN	Black Box	NO	Accuracy=86.2%	NO
(85)	Hyper AdaBoost	Black Box	NO	Accuracy= 96.8% Sensitivity = 95.4% AUC= 98.2%	NO
(86)	LDA-based Genetic Algorithm with Generalized Regression Neural Network	Black Box	NO	Accuracy=80.2% ROC=87.5%	NO
(87)	GHNN	Black Box	NO	Accuracy= 87.5% F1= 88.3% Sensitivity= 86.7% Specificity= 89.2%	NO
(88)	SIRR Convolution Trained Compositional Pattern Neural Network	Black Box	NO	Accuracy= 93.6% Sensitivity= 92.4% Specificity= 94.8% F1= 93.0% ROC= 96.2%	NO
(89)	Logistic Regression Decision Tree	white Box Black Box	NO	Accuracy=77.73%	NO
(90)	EFNNAO	Black Box	NO	Accuracy=92.2%	NO
(91)	k-NN Decision Tree	Black Box Black Box	NO	Accuracy=99.2%	NO
(92)	DNN	Black Box	NO	Accuracy=86.26%	NO
(93)	Region-Based Support Vector Machine	Black Box	NO	Accuracy=82.2%	NO
(94)	Bagging	Black Box	NO	Accuracy=99%	NO

(78)	Gradient Boosting Algorithm	Black Box	NO	Accuracy=92%	NO
(95)	FCM-FMM	Black Box	NO	Accuracy=80.96% Sensitivity =78.79% Specificity =70.27% F1 Score =74.16	NO
(96)	LightGBM	Black Box	NO	Accuracy=86%	NO
(97)	Ant Colony Optimized Neural Network	Black Box	NO	Accuracy=88.35%	NO
(98)	ANN	Black Box	NO	Accuracy=92.8%	NO
(99)	ANN	Black Box	NO	F1 Score= 0.66 Accuracy= 85% AUC= 91%	NO
(100)	Nave bayze	White Box	NO	AUC=68.9%	NO
(101)	Logistic Regression	White Box	YES	Specificity= 71.32%	NO
(102)	CNN	Black Box	NO	Accuracy =98% F1= 0.98 Sensitivity=97%	NO
(103)	MLP	Black Box	NO	Accuracy= 98%	NO
(104)	EFCS (evolving fuzzy classification systems)	Black Box	NO	Accuracy= 97.5% Sensitivity=75.78% Specificity=80.97%	NO
(105)	SVM	Black Box	YES	Accuracy= 97.22% Sensitivity= 100% Specificity= 95.65%	NO
(106)	XGBoost	Black Box	NO	Accuracy= 75.03% Sensitivity= 64.52% Specificity= 75.77% AUC= 78.05%	NO
(107)	Random Forest	Black Box	NO	AUC=89%	NO
(108)	Random Forest	Black Box	YES	AUC=91%	NO
(109)	Generalized Additive Model	Whith box	NO	Accuracy=77.6% Sensitivity= 84% Specificity= 76.1% AUC=88.4%	NO
(110)	ResNet-18 MIL	Black Box	NO	Accuracy = 80.8% Sensitivity= 90.2% AUC=87.6%	NO
(111)	WDD (weighted diversity density)	Black Box	NO	AUC =91.85%	NO
(112)	Data Space Landmark Refiner	White box	YES	Accuracy = 98.89% Sensitivity=98.97%	NO
(113)	SVM	Black Box	NO	Accuracy =94.1% Sensitivity=96.2% Specificity =94.9% F1= 95.2%	NO
(114)	ANFIS	White box	NO	Sensitivity= 84.91% Specificity= 90.1% Accuracy= 88.65%	NO
(115)	Random Forest	Black Box	NO	AUC=75.9%	NO
(116)	Bootstrap Forest	Black Box	NO	Specificity = 96.53%	NO

				<i>AUC = 99.69%</i> <i>Accuracy = 97.43%</i>	
(117)	KNN	Black Box	NO	Sensitivity= 85% F1-score= 83%	NO
(118)	RLEFRBS	Black Box	NO	<i>Accuracy=76%</i>	NO
(119)	MLP	Black Box	NO	<i>Accuracy= 89.53%</i> <i>Sensitivity= 97.10%</i> <i>Specificity= 75.62%</i>	NO
(120)	Decision Tree	Black Box	NO	<i>Sensitivity = 76%</i> <i>Accuracy=78%</i>	NO
(121)	SVM	Black Box	NO	<i>Accuracy= 78.57%</i> <i>Sensitivity= 70.91%</i> <i>F1= 70.27%</i>	NO
(122)	Hoeffding Tree	White Box	NO	<i>Sensitivity = 0.775</i>	NO
(123)	CMVRO	Black Box	NO	<i>Accuracy= 91.4%</i> <i>Sensitivity= 94.8%</i> <i>Specificity= 90.1%</i>	NO
(124)	LS-SVM	Black Box	NO	<i>Accuracy= 98.51%</i> <i>Sensitivity= 98.64%</i> <i>Specificity= 98.38%</i> <i>AUC = 98.61%</i> <i>F-score= 98.47%</i>	NO
(125)	EAGA-MLP	Black Box	NO	<i>Accuracy=97.76%</i>	NO
(126)	DNN	Black Box	NO	<i>Sensitivity= 94.63%</i> <i>Specificity= 73.34%</i> <i>Accuracy= 92.58%</i> <i>F-score= 94.22%</i>	NO
(127)	Random Forest	Black Box	NO	<i>Sensitivity=86.82%</i> <i>Accuracy = 89.24%</i> <i>F1= 88.02 %</i>	NO
(128)	ANN	Black Box	NO	<i>Accuracy =84.5%</i>	NO
(129)	Random Forest	Black Box	NO	<i>Accuracy = 97%</i>	NO
(130)	Fuzzy system	Black Box	YES	<i>Accuracy = 94%</i>	YES
(131)	ANN	Black Box	NO	<i>Accuracy =9.52%</i>	NO
(132)	MLP	Black Box	NO	<i>Accuracy=96.3%</i> <i>Sensitivity=94.8%</i>	NO
(133)	Decision Tree	Black Box	YES	<i>Accuracy=98.87%</i>	NO
(134)	XGBoost	Black Box	NO	<i>AUC=87%</i>	NO
(135)	Random Forest	Black Box	NO	<i>AUC=76.70%</i>	NO
(136)	Decision Tree	Black Box	NO	<i>Accuracy=96.1%</i>	NO
(137)	deep learning	Black Box	NO	<i>AUC=84.18</i> <i>Sensitivity=31.17</i> <i>Specificity=96.85</i> <i>Accuracy=84.28</i>	NO
(138)	HyperTab-LIME	Black Box	NO	<i>AUC=84.29%</i>	NO
(139)	Random Forest	Black Box	NO	<i>Accuracy=94%</i>	NO
(140)	Expectation-Maximization	White Box	YES	<i>Accuracy=97%</i>	NO

(141)	Mixture of Experts	Black Box	NO	Accuracy =99.36% Sensitivity =99.5% Specificity=99.7%	NO
(142)	Fuzzy system	Black Box	NO	Accuracy=100%	NO
(143)	machine learning	Black Box	NO	Accuracy =98.61% Sensitivity =97.93%	NO
(144)	Enhanced Dynamic Linear Model	White box	NO	AUC=80.4%	NO
(145)	XGBoost	Black Box	NO	Accuracy =90.36% Sensitivity =94% Specificity=83.58%	NO
(146)	CARD GA	White box	NO	Accuracy =96.05%	NO
(147)	Class Weighting	Black Box	NO	Accuracy= ۰.۹۹۴۸	NO
(148)	Dragonfly Algorithm	Black Box	NO	Accuracy =98.80%	NO
(149)	ANN	Black Box	YES	Accuracy :93.3% Sensitivity: 93.71% Specificity: 92.8%	NO
(150)	KNN	Black Box	NO	Accuracy=100	NO
(151)	Random Forest	Black Box	NO	Accurac= 0/8715 AUC= 98.11%	NO
(152)	EML	Black Box	NO	Accuracy=90.1	NO
(153)	ANN	Black Box	NO	Accuracy= 88.26% Sensitivity=86.93% Specificity =94.03%	NO
(154)	SVM	Black Box	NO	Accuracy =96.03% Sensitivity=96%	NO
(155)	NSGA-II	Black Box	NO	Accuracy= 88.18% Sensitivity=88% Specificity =94%	NO
(156)	ANFIS	White box	NO	Accuracy=89.47%	NO
(157)	Deep learning	Black Box	NO	Sensitivity=100%	NO
(158)	SVM	Black Box	NO	Accuracy = 96.58%	NO
(159)	Random Forest	Black Box	NO	Accuracy = 87.15% AUC=98.11%	NO
(160)	Random Forest	Black Box	NO	Accuracy=77.6%	NO
(161)	Firefly Algorithm	Black Box	NO	Accuracy= 97.96% Sensitivity= 98.10% Specificity= 97.82%	NO
(162)	Logistic Regression	White Box	NO	Accuracy=82.46% Sensitivity= 68.23%	NO
(163)	ANN	Black Box	NO	Accuracy=98%	NO
(164)	PLS	White Box	NO	Accuracy=91%	NO
(165)	ANN	Black Box	NO	Accuracy=98%	NO
(166)	ANFIS	Black Box	NO	Accuracy=82.30%	NO

				<i>Sensitivity= 66.23%</i> <i>Specificity= 69.76%</i>	
(167)	Adaboost k-NN LightGBM	Black Box Black Box	NO	Accuracy=90.76% <i>Sensitivity= 85.82%</i>	NO
(168)	Gradient Boosting	Black Box	NO	<i>Accuracy=95%</i> <i>Sensitivity= 66%</i> <i>AUC=98%</i>	NO
(169)	TFKNN (Tuned fuzzy KNN based on uncertainty classifiers)	Black Box	NO	<i>Accuracy= 90.63%</i> <i>Sensitivity = 93.18%</i> <i>Specificity=85.00%</i>	NO
(170)	Random Forest	Black Box	NO	Accuracy=89.63% Sensitivity= 86.87% Specificity= 89.8%	NO
(171)	EBOT	Black Box	NO	<i>Accuracy=95.81%</i>	NO
(172)	stacking ensemble	Black Box	NO	<i>Accuracy=98.46%</i>	NO
(173)	ANN	Black Box	NO	<i>Accuracy =100%</i>	NO
(174)	MJ48	Black Box	NO	Accuracy=96.84% Sensitivity= 93%	NO
(175)	Particle Swarm Optimization Fuzzy C-Means	Black Box	NO	Accuracy=95.5% Sensitivity=96.5% Specificity=93.5%	NO
(176)	Decision Tree	Black Box	NO	<i>Accuracy= 88%</i> <i>Sensitivity = 89%</i> <i>AUC= 89%</i>	NO
(177)	ANN	Black Box	NO	<i>Accuracy = 94.1%</i> <i>sensitivity = 90%</i> <i>specificity=95.5%</i>	NO
(178)	SVM	Black Box	NO	<i>Accuracy = 94.1%</i> <i>sensitivity = 96.2%</i> <i>specificity = 94.9%</i> <i>F1 score =95.2%</i>	NO
(179)	Clustering	Black Box	NO	<i>Accuracy = 79%</i>	NO
(180)	Clustering	Black Box	NO	<i>Accuracy=79%</i> <i>sensitivity = 50%</i>	NO
(181)	Logistic Regression	White Box	NO	<i>sensitivity =98%</i>	NO
(182)	Grey Wolf Optimization	Black Box	NO	Accuracy=71%	NO
(183)	MLP	Black Box	NO	Accuracy=93.51%	NO
(184)	Logistic Regression	White Box	NO	accuracy=81%	NO
(185)	ANN	Black Box	NO	Accuracy=92.8%	NO
(186)	Deep learning	Black Box	NO	<i>accuracy = 86.31%</i> <i>AUC =82.70</i>	NO
(187)	ANN ACO	Black Box	NO	Accuracy=99.24%	NO
(188)	NSGA-II-Stacking	Black Box	NO	<i>Accuracy =83.8%</i> <i>sensitivity =96.1%</i>	NO

				<i>specificity =79.9%</i> <i>f-measure =88.5</i> <i>AUC =85.9</i>	
(189)	ANN	Black Box	NO	<i>Accuracy= 86.7%</i> <i>Sensitivity= 80%</i> <i>Specificity= 93.3%</i>	NO
(190)	Fuzzy system	Black Box	NO	Accuracy=97.33%	NO
(191)	MLP	Black Box	NO	<i>Specificity= 95%</i> <i>sensitivity =97%</i> <i>accuracy=97%</i>	NO
(192)	DNN	Black Box	YES	AUC=84%	NO
(193)	ABC-DNN	Black Box	NO	Accuracy=94.74%	NO
(194)	J48	White Box	NO	Accuracy=991.38%	NO
(195)	SVM	Black Box	NO	Accuracy =100%	NO
(196)	DeepNetX2	Black Box	NO	Accuracy=97.87%	NO
(197)	RCE-IFE	Black Box	NO	AUC=72%	NO
(198)	Random Forest	Black Box	NO	<i>Accuracy: 94.7%</i> <i>Sensitivity: 92%</i> <i>Specificity: 95%</i>	NO
(199)	Logistic Regression	White Box	NO	<i>Accuracy=75.32%</i> <i>Sensitivity= 86%</i> <i>Specificity= 55.56%</i>	NO
(200)	Decision Tree	Black Box	NO	Accuracy=75.91%	YES
(201)	Random Forest	Black Box	NO	<i>Accuracy= 98.86%</i> <i>Sensitivity =98.86%</i>	YES
(202)	ANFIS	Black Box	NO	<i>Accuracy= 98.14%</i> <i>Sensitivity =96.97%</i> <i>Specificity=95.58%</i>	NO
(203)	RBF	Black Box	NO	Accuracy=79%	NO
(204)	AdaBoost	Black Box	NO	Accuracy=80.72%	NO
(205)	SVM	Black Box	yes	Accuracy=88%	NO
(206)	GBDT	Black Box	NO	<i>Accuracy=78.83%</i> <i>Sensitivity =82.99%</i> <i>F1-Measure= 79.01%</i> <i>AUC= 86.72%</i>	NO
(207)	PNN	Black Box	NO	Accuracy=92.5%	NO
(208)	SVM	Black Box	NO	<i>Accuracy=80%</i> <i>Sensitivity =75%</i> <i>Specificity= 81%</i>	NO
(209)	Support Vector Classifier	Black Box	NO	<i>Accuracy=99.4%</i> <i>Sensitivity =100%</i>	NO
(210)	K-Means	Black Box	NO	Accuracy=95.42%	NO
(211)	LapSVM	Black Box	NO	<i>Accuracy=82.29%</i> <i>Sensitivity= 86.40%</i> <i>Specificity= 86.40%</i>	NO
(212)	SqueezeNet	Black Box	NO	Accuracy= 87.35%	NO

				Sensitivity= 89.29%	
				Specificity=85.40%	
				AUC= 93.4%	
(213)	ANN	Black Box	NO	Accuracy= 82.4% Sensitivity= 37.8% Specificity= 90.2% AUC= 79.49%	NO
(214)	XGBoost	Black Box	NO	Accuracy= 93.75% Sensitivity= 91.79% Specificity=94.8% AUC= 97.81%	NO
(215)	Ensemble Learning	Black Box	NO	Sensitivity =52.53 F1 = 73.59	NO
(216)	CNN	Black Box	NO	Accuracy= 92 Sensitivity= 95 Specificity= 95 F1-score= 0.95 AUC= 99.5%	NO
(217)	Genetic Algorithm XGBoost	Black Box	NO	Accuracy=97.28% F1-Score: 0.97%	NO
(218)	Random Forest	Black Box	NO	Accuracy=85.9%	NO
(219)	AHDHS-Stacking	Black Box	NO	Accuracy= 93.09% Sensitivity =91.60% F-Measure: 92.25%	NO
(220)	CNN	Black Box	NO	Accuracy=94.12%	NO
(221)	XGBoost Random Forest LightGBM	Black Box	NO	AUC=84.7%	NO
(222)	FNN	Black Box	NO	Accuracy= 87.69 Sensitivity= 44.88	NO

Attached resources

- Abiyev RH, Altiparmak H. Type-2 Fuzzy Neural System for Diagnosis of Diabetes. *Mathematical Problems in Engineering*. 2021;2021.
- Adlakha M, Naaz S, Zafar S, Alam MA, editors. Deep Learning Approach for Accurate Prediction of diabetes. *ACM International Conference Proceeding Series*; 2023.
- Agliata A, Giordano D, Bardozzo F, Bottiglieri S, Facchiano A, Tagliaferri R. Machine Learning as a Support for the Diagnosis of Type 2 Diabetes. *International Journal of Molecular Sciences*. 2023;24(7).
- Ahmed KF, Uz Zaman MS, Peyal HI, Hossain A, Rahman Ratul MT, Abdal MN, et al., editors. An Interpretable Framework for Predicting Type 2 Diabetes using ML and Explainable AI. *2023 26th International Conference on Computer and Information Technology, ICCIT 2023*; 2023.
- Akula R, Nguyen N, Garibay I, editors. Supervised Machine Learning based Ensemble Model for Accurate Prediction of Type 2 Diabetes. *Conference Proceedings - IEEE SOUTHEASTCON*; 2019.
- Al Sadi K, Balachandran W. Prediction Model of Type 2 Diabetes Mellitus for Oman Prediabetes Patients Using Artificial Neural Network and Six Machine Learning Classifiers. *Applied Sciences (Switzerland)*. 2023;13(4).
- Alade OM, Sowunmi OY, Misra S, Maskeliunas R, Damasevicius R, editors. A Neural Network Based Expert System for the Diagnosis of Diabetes Mellitus. *International Conference on Information Technology Science (MosITS)*; 2017 Dec 01-03; Moscow, RUSSIA2018.
- Alassaf RA, Alsulaim KA, Alroomi NY, Alsharif NS, Aljubeir MF, Olatunji SO, et al., editors. Preemptive Diagnosis of Diabetes Mellitus Using Machine Learning. *21st Saudi-Computer-Society National Computer Conference (NCC)*; 2018 Apr 25-26; Riyadh, SAUDI ARABIA2018.
- Alenizi AS, Al-karawi KA, editors. Machine Learning Approach for Diabetes Prediction. *Lecture Notes in Networks and Systems*; 2024.
- Alhassan Z, McGough AS, Alshammari R, Daghestani T, Budgen D, Al Moubayed N, editors. Type-2 diabetes mellitus diagnosis from time series clinical data using deep learning models. *Lecture Notes in Computer Science (including subseries Lecture Notes*

- in *Artificial Intelligence and Lecture Notes in Bioinformatics*); 2018.
11. Alhmiedat T, Alotaibi M. The Investigation of Employing Supervised Machine Learning Models to Predict Type 2 Diabetes Among Adults. *KSII Transactions on Internet and Information Systems*. 2022;16(9):2904-26.
 12. Alimova D, Ikramov A, Trigulova R, Abdullaeva S, Mukhtarova S, editors. Prediction of diastolic dysfunction in patients with cardiovascular diseases and type 2 diabetes with respect to covid-19 in anamnesis using artificial intelligence. *ACM International Conference Proceeding Series*; 2023.
 13. Almadni D, Abhari A, editors. Comparative analysis of classification models in diagnosis of type 2 diabetes. *Simulation Series*; 2016.
 14. Alsadi B, Musleh S, Al-Absi HRH, Refae M, Qureshi R, El Hajj N, et al. An ensemble-based machine learning model for predicting type 2 diabetes and its effect on bone health. *BMC Medical Informatics and Decision Making*. 2024;24(1).
 15. Altıparmak H, Abiyev R, Tüzünkan M, editors. Diagnosis of Diabetes Using Type-2 Fuzzy System. *4th International Conference on Intelligent and Fuzzy Systems (INFUS)*; 2022 Jul 19-21; Bornova, TURKEY2022.
 16. Alzboon MS, Al-Batah MS, Alqaraleh M, Abuashour A, Bader AFH. Early Diagnosis of Diabetes: A Comparison of Machine Learning Methods. *International Journal of Online and Biomedical Engineering*. 2023;19(15):144-65.
 17. Anwar NHK, Saian R, Bakar SA, editors. An enhanced ant colony optimization with Gini index for predicting type 2 diabetes. *AIP Conference Proceedings*; 2021.
 18. Ashok Kumar M, Laurence Aroquiaraj I. Improved K-Means with Adaptive Divergence Weight Bat Algorithm (IKM-ADWBA) and Feature Selection for Type 2 Diabetes Mellitus Prediction. *International Journal of Recent Technology and Engineering*. 2019;8(2S11):288-99.
 19. Balasubramaniyan S, Jeyakumar V, Nachimuthu DS. Panoramic tongue imaging and deep convolutional machine learning model for diabetes diagnosis in humans. *Scientific Reports*. 2022;12(1).
 20. Barakat N, Bradley AP, Barakat MNH. Intelligible support vector machines for diagnosis of diabetes mellitus. *IEEE Transactions on Information Technology in Biomedicine*. 2010;14(4):1114-20.
 21. Battineni G, Sagaro GG, Nalini C, Amenta F, Tayebati SK. Comparative machine-learning approach: A follow-up study on type 2 diabetes predictions by cross-validation methods. *Machines*. 2019;7(4).
 22. Benamina M, Atmani B, Benbelkacem S. Diabetes Diagnosis by Case-Based Reasoning and Fuzzy Logic. *International Journal of Interactive Multimedia and Artificial Intelligence*. 2018;5(3):72-80.
 23. Bernardini M, Romeo L, Misericordia P, Frontoni E. Discovering the Type 2 Diabetes in Electronic Health Records Using the Sparse Balanced Support Vector Machine. *IEEE Journal of Biomedical and Health Informatics*. 2020;24(1):235-46.
 24. Bernstorff M, Hansen L, Enevoldsen K, Damgaard J, Hæstrup F, Perfalk E, et al. Development and validation of a machine learning model for prediction of type 2 diabetes in patients with mental illness. *Acta Psychiatrica Scandinavica*. 2024.
 25. Birjais R, Mourya AK, Chauhan R, Kaur H. Prediction and diagnosis of future diabetes risk: a machine learning approach. *Sn Applied Sciences*. 2019;1(9).
 26. Borzouei S, Soltanian AR. Application of an artificial neural network model for diagnosing type 2 diabetes mellitus and determining the relative importance of risk factors. *Epidemiology and Health*. 2018;40.
 27. Caixeta DC, Carneiro MG, Rodrigues R, Alves DCT, Goulart LR, Cunha TM, et al. Salivary ATR-FTIR Spectroscopy Coupled with Support Vector Machine Classification for Screening of Type 2 Diabetes Mellitus. *Diagnostics*. 2023;13(8).
 28. Çalisir D, Dogantekin E. An automatic diabetes diagnosis system based on LDA-Wavelet Support Vector Machine Classifier. *Expert Systems with Applications*. 2011;38(7):8311-5.
 29. Çamur SN, Uçar MK, Ieee, editors. Rule-Based Artificial Intelligence Algorithm for Early Diabetes Diagnosis. *Medical Technologies Congress (TIPEKNO'21)*; 2021 Nov 04-06; Antalya, TURKEY2021.
 30. Chang V, Kandadai K, Xu QWA, Guan S. Development of a Diabetes Diagnosis System Using Machine Learning Algorithms. *International Journal of Distributed Systems and Technologies*. 2022;13(1).
 31. Chatrati SP, Hossain G, Goyal A, Bhan A, Bhattacharya S, Gaurav D, et al. Smart home health monitoring system for predicting type 2 diabetes and hypertension. *Journal of King Saud University - Computer and Information Sciences*. 2022;34(3):862-70.
 32. Chaves L, Marques G. Data Mining Techniques for Early Diagnosis of Diabetes: A Comparative Study. *Applied Sciences-Basel*. 2021;11(5).
 33. Chellappan D, Rajaguru H. Machine Learning Meets Meta-Heuristics: Bald Eagle Search Optimization and Red Deer Optimization for Feature Selection in Type II Diabetes Diagnosis. *Bioengineering-Basel*. 2024;11(8).
 34. Chen H, Tan C. Prediction of type-2 diabetes based on several element levels in blood and chemometrics. *Biological Trace Element Research*. 2012;147(1-3):67-74.
 35. Chen TH, Shang CJ, Su P, Antoniou G, Shen Q, editors. Effective Diagnosis of Diabetes with a Decision Tree-Initialised Neuro-fuzzy Approach. *18th UK Workshop on Computational Intelligence (UKCI)*; 2018 Sep 05-07; Nottingham Trent Univ, Nottingham, ENGLAND2019.
 36. Chen W, Chen S, Zhang H, Wu T, editors. A hybrid prediction model for type 2 diabetes using K-means and decision tree. *Proceedings of the IEEE International Conference on Software Engineering and Service Sciences, ICSESS*; 2017.

37. Chikh MA, Saidi M, Settouti N. Diagnosis of Diabetes Diseases Using an Artificial Immune Recognition System² (AIRS²) with Fuzzy K-nearest Neighbor. *Journal of Medical Systems*. 2012;36(5):2721-9.
38. Choudhury A, Gupta D, editors. A Survey on Medical Diagnosis of Diabetes Using Machine Learning Techniques. *2nd International Conference on Computing and Communication (IC3)*; 2018 Mar 23-24; Rangpo, INDIA2019.
39. Daanouni O, Cherradi B, Tmiri A. Type 2 Diabetes Mellitus Prediction Model Based on Machine Learning Approach. *Lecture Notes in Intelligent Transportation and Infrastructure*. Part F14092020. p. 454-69.
40. Daghistani T, Alshammari R. Diagnosis of Diabetes by Applying Data Mining Classification Techniques Comparison of Three Data Mining Algorithms. *International Journal of Advanced Computer Science and Applications*. 2016;7(7):329-32.
41. Deng J, Dai S, Liu S, Tu L, Cui J, Hu X, et al. Application of tongue image characteristics and oral-gut microbiota in predicting pre-diabetes and type 2 diabetes with machine learning. *Frontiers in Cellular and Infection Microbiology*. 2024;14.
42. Dritsas E, Trigka M. Data-Driven Machine-Learning Methods for Diabetes Risk Prediction. *Sensors*. 2022;22(14).
43. Duc L, Tung NT, Oanh TT, Tri NQ, Linh NT. Non-Invasive In Vivo Type 2 Diabetes Mellitus Diagnosis Using Raman Spectroscopy in Combination with Machine Learning. *Mobile Networks & Applications*. 2023.
44. Ebrahim OA, Derbew G. Application of supervised machine learning algorithms for classification and prediction of type-2 diabetes disease status in Afar regional state, Northeastern Ethiopia 2021. *Scientific Reports*. 2023;13(1).
45. Echajei S, Hafdane M, Ferjouchia H, Rachik M. Integrating Causal Inference and Machine Learning for Early Diagnosis and Management of Diabetes. *International Journal of Advanced Computer Science and Applications*. 2024;15(6):578-84.
46. El Kebraoui F, En-Naimi EM, El Ghouch N, editors. A Comparative Study of Different Supervised Machine Learning in Predicting of Type 2 Diabetes. *ACM International Conference Proceeding Series*; 2023.
47. Ellouze A, Kahouli O, Ksantini M, Alsaif H, Aloui A, Kahouli B. Artificial Intelligence-Based Diabetes Diagnosis with Belief Functions Theory. *Symmetry-Basel*. 2022;14(10).
48. El-Sappagh S, Alonso JM, Ali F, Ali A, Jang JH, Kwak KS. An Ontology-Based Interpretable Fuzzy Decision Support System for Diabetes Diagnosis. *Ieee Access*. 2018;6:37371-94.
49. El-Sappagh S, Elmogy M, Riad AM. A fuzzy-ontology-oriented case-based reasoning framework for semantic diabetes diagnosis. *Artificial Intelligence in Medicine*. 2015;65(3):179-208.
50. Enisa M, Belma N, Adin N, Enisa N, Ines N, Nejla O, editors. Artificial Intelligence in Type 2 Diabetes. *IFMBE Proceedings*; 2021.
51. ErKaymaz O, Ozer M. Impact of small-world network topology on the conventional artificial neural network for the diagnosis of diabetes. *Chaos Solitons & Fractals*. 2016;83:178-85.
52. Eyasu K, Jimma W, Tadesse T. Developing a Prototype Knowledge-Based System for Diagnosis and Treatment of Diabetes Using Data Mining Techniques. *Ethiopian Journal of Health Sciences*. 2020;30(1):115-24.
53. Fang T, Li YP, Li FC, Huang FR. Rapid Diagnosis of Type II Diabetes Using Fourier Transform Mid-Infrared Attenuated Total Reflection Spectroscopy Combined with Support Vector Machine. *Analytical Letters*. 2018;51(9):1400-16.
54. Fatemidokht H, Rafsanjani MK, editors. Development of a hybrid neuro-fuzzy system as a diagnostic tool for Type 2 Diabetes Mellitus. *2018 6th Iranian Joint Congress on Fuzzy and Intelligent Systems, CFIS 2018*; 2018.
55. Frimpong EA, Oluwasanmi A, Baagyere EY, Zhiguang Q, editors. A feedforward artificial neural network model for classification and detection of type 2 diabetes. *Journal of Physics: Conference Series*; 2021.
56. Gangu BK, Satyanarayana Murthy N, Ganta A, Gedela VS, editors. Predicting Type 2 Diabetes Using Machine Learning and Flask Web Framework. *International Conference on Artificial Intelligence for Innovations in Healthcare Industries, ICAIHI 2023*; 2023.
57. Gangula R, Sudha C, Sreeveda K, Bonagiri R, Bhagyashree C, Saturi S, editors. Prediction and Prognosis of Diabetes Using Logistic Regression. *2022 IEEE North Karnataka Subsection Flagship International Conference, NKCon 2022*; 2022.
58. Ganie SM, Malik MB, Arif T. Performance analysis and prediction of type 2 diabetes mellitus based on lifestyle data using machine learning approaches. *Journal of Diabetes and Metabolic Disorders*. 2022;21(1):339-52.
59. Ganji MF, Abadeh MS. A fuzzy classification system based on Ant Colony Optimization for diabetes disease diagnosis. *Expert Systems with Applications*. 2011;38(12):14650-9.
60. Garcia-Rios V, Marres-Salhuana M, Sierra-Liñan F, Cabanillas-Carbonell M. Predictive machine learning applying cross industry standard process for data mining for the diagnosis of diabetes mellitus type 2. *IAES International Journal of Artificial Intelligence*. 2023;12(4):1713-26.
61. Gayathri R, Pati PB, Singh T, Nair RR, editors. A Framework for the prediction of Diabetes Mellitus using Hyper-Parameter tuned XGBoost Classifier. *2022 13th International Conference on Computing Communication and Networking Technologies, ICCCNT 2022*; 2022.
62. Giveki D, Rastegar H. Designing a New Radial Basis Function Neural Network by Harmony Search for Diabetes Diagnosis. *Optical Memory and Neural Networks*. 2019;28(4):321-31.
63. Gowthami S, Reddy RVS, Ahmed MR, editors. Early Diagnosis of Type-2 Diabetes Mellitus Using Machine Learning Approaches for Accurate Diabetes

- Management. *International Conference on Artificial Intelligence for Innovations in Healthcare Industries, ICAIHI 2023*; 2023.
64. Gowthami S, Reddy VS, Ahmed MR. Type 2 Diabetes Mellitus: Early Detection using Machine Learning Classification. *International Journal of Advanced Computer Science and Applications*. 2023;14(6):1191-8.
 65. Goyal P, Jain S, editors. Prediction of Type-2 Diabetes using Classification and Ensemble Method Approach. *2022 International Mobile and Embedded Technology Conference, MECON 2022*; 2022.
 66. Grande-Ramírez JR, Meza-Palacios R, Lasserre AAA, Flores-Asis R, Vázquez-Rodríguez CF. Intelligent fuzzy system to assess the risk of type 2 diabetes and diagnosis in marginalized regions. *IAES International Journal of Artificial Intelligence*. 2024;13(2):1933-42.
 67. Guo H, Fan ZC, Zeng Y. Novel Data Mining Analysis Method on Risk Prediction of Type 2 Diabetes. *Journal of Signal Processing Systems*. 2022;94(11):1183-98.
 68. Habibi S, Ahmadi M, Alizadeh S. Type 2 Diabetes Mellitus Screening and Risk Factors Using Decision Tree: Results of Data Mining. *Global journal of health science*. 2015;7(5):304-10.
 69. Hadžalić S, Obralića A, Bećirović Š, Kelle BP, Krupalija E, editors. Analysis of Predictive Parameters in Prediction of the Occurrence of Type 2 Diabetes Using Machine Learning Algorithms. *IFMBE Proceedings*; 2024.
 70. Hahn SJ, Kim S, Choi YS, Lee J, Kang J. Prediction of type 2 diabetes using genome-wide polygenic risk score and metabolic profiles: A machine learning analysis of population-based 10-year prospective cohort study. *eBioMedicine*. 2022;86.
 71. Han YM, Yang H, Huang QL, Sun ZJ, Li ML, Zhang JB, et al. Risk prediction of diabetes and pre-diabetes based on physical examination data. *Mathematical Biosciences and Engineering*. 2022;19(4):3597-608.
 72. Hao JW, Luo SL, Pan LM. Rule extraction from biased random forest and fuzzy support vector machine for early diagnosis of diabetes. *Scientific Reports*. 2022;12(1).
 73. He B, Shu KG, Zhang H, Soc IC, editors. Diabetes diagnosis and treatment research based on machine learning. *IEEE Conference on SmartWorld, Ubiquitous Intelligence and Computing, Advanced and Trusted Computing, Scalable Computing and Communications, Cloud and Big Data Computing, Internet of People and Smart City Innovation*; 2019 Aug 19-23; Leicester, ENGLAND2019.
 74. Hebbale A, Vinay GHR, Krishna BVNV, Shah J, editors. IoT and Machine Learning based Self Care System for Diabetes Monitoring and Prediction. *2021 2nd Global Conference for Advancement in Technology, GCAT 2021*; 2021.
 75. Hernández-Rubio E, Jaimes Mackay CA, Robles Sosa PG, Galicia-Mejía R, editors. Web System for the Prediction of Type II Diabetes Based on Machine Learning. *Communications in Computer and Information Science*; 2024.
 76. Heydari M, Teimouri M, Heshmati Z, Alavinia SM. Comparison of various classification algorithms in the diagnosis of type 2 diabetes in Iran. *International Journal of Diabetes in Developing Countries*. 2016;36(2):167-73.
 77. Hossain E, Alshehri M, Almakdi S, Halawani H, Rahman MM, Rahman W, et al. Dm-Health App: Diabetes Diagnosis Using Machine Learning with Smartphone. *Cmc-Computers Materials & Continua*. 2022;72(1):1713-46.
 78. Hossain ME, Uddin S, Khan A. Network analytics and machine learning for predictive risk modelling of cardiovascular disease in patients with type 2 diabetes. *Expert Systems with Applications*. 2021;164.
 79. Huang LC, Lu CC, Ieee, editors. Intelligent Diagnosis of Diabetes based on Informal Gain and Deep Neural Network. *5th IEEE International Conference on Cloud Computing and Intelligence Systems (CCIS)*; 2018 Nov 23-25; Nanjing, PEOPLES R CHINA2018.
 80. Ijaz MF, Alfian G, Syafrudin M, Rhee J. Hybrid Prediction Model for type 2 diabetes and hypertension using DBSCAN-based outlier detection, Synthetic Minority Over Sampling Technique (SMOTE), and random forest. *Applied Sciences (Switzerland)*. 2018;8(8).
 81. Islam MM, Rifat HR, Shahid MSB, Akhter A, Uddin MA, Uddin KMM. Explainable Machine Learning for Efficient Diabetes Prediction Using Hyperparameter Tuning, SHAP Analysis, Partial Dependency, and LIME. *Engineering Reports*. 2024.
 82. Islam MS, Qaraqe MK, Abbas HT, Erraguntla M, Abdul-Ghani M, editors. The prediction of diabetes development: A machine learning framework. *Middle East Conference on Biomedical Engineering, MECBME*; 2020.
 83. Islam R, Sultana A, Tuhin MN, Saikat MSH, Islam MR. Clinical Decision Support System for Diabetic Patients by Predicting Type 2 Diabetes Using Machine Learning Algorithms. *Journal of Healthcare Engineering*. 2023;2023.
 84. Jagini A, Gayatri N, Nagaraju S, Rao VS, Rao KS, Sumanth B, editors. Prediction of Diabetes at early stages using ANN & Outlier Exposure. *Proceedings of the 2022 International Conference on Innovative Computing, Intelligent Communication and Smart Electrical Systems, ICSES 2022*; 2022.
 85. Jasim AA, Hazim LR, Mohammedqasim H, Mohammedqasem R, Ata O, Salman OH. e-Diagnostic system for diabetes disease prediction on an IoMT environment-based hyper AdaBoost machine learning model. *Journal of Supercomputing*. 2024;80(11):15664-89.
 86. Jayashree J, Kumar SA. Linear Discriminant Analysis Based Genetic Algorithm with Generalized Regression Neural Network - A Hybrid Expert System for Diagnosis of Diabetes. *Programming and Computer Software*. 2018;44(6):417-27.
 87. Jayashree J, Kumar SA. Evolutionary correlated gravitational search algorithm (ECGS) with genetic optimized Hopfield neural network (GHNN) - A

- hybrid expert system for diagnosis of diabetes. *Measurement*. 2019;145:551-8.
88. Jayashree J, Kumar SA. Hybrid swarm intelligent redundancy relevance (RR) with convolution trained compositional pattern neural network expert system for diagnosis of diabetes. *Health and Technology*. 2020;10(1):197-206.
 89. Joshi RD, Dhakal CK. Predicting type 2 diabetes using logistic regression and machine learning approaches. *International Journal of Environmental Research and Public Health*. 2021;18(14).
 90. Jothi SA, Samath JA, editors. Enhanced Feed Forward Neural Network with Adam Optimization Model (Efnnao) for Predicting the Type 2 Diabetes Using Internet of Things. *Proceedings of 5th International Conference on Contemporary Computing and Informatics, IC3I 2022*; 2022.
 91. Kalhor R, Mortezaigholi A, Naji F, Shahsavari S, Kiaei MZ. Designing an intelligent system for diagnosing type 2 diabetes using the data mining approach: Brief report. *Tehran University Medical Journal*. 2019;76(12):827-31.
 92. Kannadasan K, Edla DR, Kuppili V. Type 2 diabetes data classification using stacked autoencoders in deep neural networks. *Clinical Epidemiology and Global Health*. 2019;7(4):530-5.
 93. Karatsiolis S, Schizas CN, editors. Region based Support Vector Machine Algorithm for Medical Diagnosis on Pima Indian Diabetes DataSet. *12th IEEE International Conference on BioInformatics and BioEngineering (BIBE)*; 2012 Nov 11-13; Larnaca, CYPRUS2012.
 94. Katiyar N, Thakur HK, Ghatak A, Raj M, editors. Type-2 Diabetes Mellitus Prediction Through Ensemble Learning Technique Based on Gene Data and Machine Learning Approach. *Lecture Notes in Networks and Systems*; 2024.
 95. Kim KB, Park HJ, Song DH. Combining Supervised and Unsupervised Fuzzy Learning Algorithms for Robust Diabetes Diagnosis. *Applied Sciences-Basel*. 2023;13(1).
 96. Kopitar L, Fister I, Stiglic G. Using Generative AI to Improve the Performance and Interpretability of Rule-Based Diagnosis of Type 2 Diabetes Mellitus. *Information (Switzerland)*. 2024;15(3).
 97. Kumar M, Sharma A, Agarwal S, Ieee, editors. Clinical Decision Support System for Diabetes Disease Diagnosis Using Optimized Neural Network. *Students Conference on Engineering and Systems (SCES)*; 2014 May 28-30; Allahabad, INDIA2014.
 98. Kumari S, Singh A, editors. A Data Mining Approach for the Diagnosis of Diabetes Mellitus. *7th International Conference on Intelligent Systems and Control (ISCO)*; 2013 Jan 04-05; Coimbatore, INDIA2013.
 99. Lavikainen P, Chandra G, Siirtola P, Tamminen S, Ihalapathirana AT, Rönning J, et al. Data-Driven Identification of Long-Term Glycemia Clusters and Their Individualized Predictors in Finnish Patients with Type 2 Diabetes. *Clinical Epidemiology*. 2023;15:13-29.
 100. Lee BJ, Ku B, Nam J, Pham DD, Kim JY. Prediction of fasting plasma glucose status using anthropometric measures for diagnosing Type 2 diabetes. *IEEE Journal of Biomedical and Health Informatics*. 2014;18(2):555-61.
 101. Lee J, Keam B, Jang EJ, Park MS, Lee JY, Kim DB, et al. Development of a Predictive Model for Type 2 Diabetes Mellitus Using Genetic and Clinical Data. *Osong Public Health and Research Perspectives*. 2011;2(2):75-82.
 102. Lee JE, Jeon HJ, Lee OJ, Lim HG. Diagnosis of diabetes mellitus using high frequency ultrasound and convolutional neural network. *Ultrasonics*. 2024;136.
 103. Lee WS, Jo J, Song T. Machine learning for the diagnosis of early-stage diabetes using temporal glucose profiles. *Journal of the Korean Physical Society*. 2021;78(5):373-8.
 104. Lekkas S, Mikhailov L. Evolving fuzzy medical diagnosis of Pima Indians diabetes and of dermatological diseases. *Artificial Intelligence in Medicine*. 2010;50(2):117-26.
 105. Li Y, Guo L, Li L, Yang C, Guang P, Huang F, et al. Early Diagnosis of Type 2 Diabetes Based on Near-Infrared Spectroscopy Combined With Machine Learning and Aquaphotomics. *Frontiers in Chemistry*. 2020;8.
 106. Liu Q, Zhang M, He Y, Zhang L, Zou J, Yan Y, et al. Predicting the Risk of Incident Type 2 Diabetes Mellitus in Chinese Elderly Using Machine Learning Techniques. *Journal of Personalized Medicine*. 2022;12(6).
 107. López B, Torrent-Fontbona F, Viñas R, Fernández-Real JM. Single Nucleotide Polymorphism relevance learning with Random Forests for Type 2 diabetes risk prediction. *Artificial Intelligence in Medicine*. 2018;85:43-9.
 108. Lu H, Uddin S, Hajati F, Moni MA, Khushi M. A patient network-based machine learning model for disease prediction: The case of type 2 diabetes mellitus. *Applied Intelligence*. 2022;52(3):2411-22.
 109. Luo G. Automatically explaining machine learning prediction results: A demonstration on type 2 diabetes risk prediction. *Health Information Science and Systems*. 2016;4(1).
 110. Lv W, Fu R, Lin X, Su Y, Jin X, Yang H, et al., editors. A non-invasive diabetes diagnosis method based on novel scleral imaging instrument and AI. *Proceedings of SPIE - The International Society for Optical Engineering*; 2021.
 111. Lv X, Luo J, Huang W, Guo H, Bai X, Yan P, et al. Identifying diagnostic indicators for type 2 diabetes mellitus from physical examination using interpretable machine learning approach. *Frontiers in Endocrinology*. 2024;15.
 112. Lv X, Luo J, Zhang Y, Guo H, Yang M, Li M, et al. Unveiling diagnostic information for type 2 diabetes through interpretable machine learning. *Information Sciences*. 2025;690.
 113. Mahajan A, Kumar S, Bansal R, editors. Diagnosis of Diabetes Mellitus Using PCA and Genetically Optimized Neural Network. *IEEE International Conference on Computing, Communication and Automation (ICCCA)*; 2017 May 05-06; Noida, INDIA2017.

114. Mamuda M, Sathasivam S. The development of Adaptive Neuro-Fuzzy Inference System model to diagnosis diabetes disease data set. *Matematika*. 2017;33(1):11-9.
115. Mani S, Chen Y, Elasy T, Clayton W, Denny J. Type 2 diabetes risk forecasting from EMR data using machine learning. *AMIA Annual Symposium proceedings / AMIA Symposium AMIA Symposium*. 2012;2012:606-15.
116. Mansoori A, Sahranavard T, Hosseini ZS, Soflaei SS, Emrani N, Nazar E, et al. Prediction of type 2 diabetes mellitus using hematological factors based on machine learning approaches: a cohort study analysis. *Scientific Reports*. 2023;13(1).
117. Mansouri S, Boulares S, Chabchoub S. Machine Learning for Early Diabetes Detection and Diagnosis. *Journal of Wireless Mobile Networks, Ubiquitous Computing, and Dependable Applications*. 2024;15(1):216-30.
118. Mansourypoor F, Asadi S. Development of a Reinforcement Learning-based Evolutionary Fuzzy Rule-Based System for diabetes diagnosis. *Computers in Biology and Medicine*. 2017;91:337-52.
119. Marcano-Cedeno A, Andina D, editors. Data mining for the diagnosis of type 2 diabetes. *World Automation Congress Proceedings*; 2012.
120. Medina-Pérez VM, Zúñiga-Mondragón I, Cruz-Ramos JA, Arellano-Arteaga KJ, Rusanova I, García-Gil G, et al., editors. Machine Learning Model to Classify Patients with Complicated and Uncomplicated Type 2 Diabetes Mellitus in the New Civil Hospital of Guadalajara "Juan I. Menchaca". *IFMBE Proceedings*; 2024.
121. Mekale SS, Chakraborty M, Mukherjee C, editors. Type 2 Diabetes Classification and Prediction: An Ensemble and Hyper Parameter Optimization Approach in Machine Learning. *International Conference on Artificial Intelligence for Innovations in Healthcare Industries, ICAIHI 2023*; 2023.
122. Mercaldo F, Nardone V, Santone A, editors. Diabetes Mellitus Affected Patients Classification and Diagnosis through Machine Learning Techniques. *21st International Conference on Knowledge - Based and Intelligent Information and Engineering Systems (KES)*; 2017 Sep 06-08; Aix Marseille Univ, St Charles Campus, Marseille, FRANCE2017.
123. Middha K, Mittal A. Discovery of type 2 diabetes mellitus with correlation and optimization driven hybrid deep learning approach. *Computer Methods in Biomechanics and Biomedical Engineering*. 2024;27(13):1931-43.
124. Mishra B, Nirala N, Singh BK. Photoplethysmography signal-based automated diagnosis of type-2 diabetes using tunable-Q wavelet transform and least-square support vector machine classifier. *Signal Image and Video Processing*. 2023;17(6):2745-54.
125. Mishra S, Tripathy HK, Mallick PK, Bhoi AK, Barsocchi P. Eaga-mlp—an enhanced and adaptive hybrid classification model for diabetes diagnosis. *Sensors (Switzerland)*. 2020;20(14):1-34.
126. Mohamed AT, Santhoshkumar S. Deep learning based process analytics model for predicting type 2 diabetes mellitus. *Computer Systems Science and Engineering*. 2022;40(1):191-205.
127. Morgan-Benita JA, Celaya-Padilla JM, Luna-García H, Galván-Tejada CE, Cruz M, Galván-Tejada JI, et al. Setting Ranges in Potential Biomarkers for Type 2 Diabetes Mellitus Patients Early Detection By Sex—An Approach with Machine Learning Algorithms. *Diagnostics*. 2024;14(15).
128. Mortajez S, Jamshidinezhad A. An Artificial Neural Network Model to Diagnosis of Type II Diabetes. *Journal of Research in Medical and Dental Science*. 2019;7(1):66-70.
129. Mounika V, Neeli DS, Sree GS, Mourya P, Babu MA, editors. Prediction of Type-2 Diabetes using Machine Learning Algorithms. *Proceedings - International Conference on Artificial Intelligence and Smart Systems, ICAIS 2021*; 2021.
130. Mujawar IK, Jadhav BT, Waghmare VB, Patil RY, Ieee, editors. Online approach for Diabetes Diagnosis and Classification with Expert System Modules using Fuzzy Logic. *2nd IEEE-Pune-Section Annual International Conference (IEEE PuneCon)*; 2019 Dec 18-20; MIT World Peace Univ, Sch Elect & Commun, MIT Coll Engn, Pune, INDIA2019.
131. Mujawar IK, Jadhav BT, Waghmare VB, Patil RY, Ieee, editors. Development of Diabetes Diagnosis System with Artificial Neural Network and Open Source Environment. *3rd IEEE International Conference on Emerging Smart Computing and Informatics (IEEE-ESCI)*; 2021 Mar 05-07; All India Shri Shivaji Memorial Soc Inst Informat Technol, Pune, INDIA2021.
132. Mythili J, Surendhar T, Suryaprakash P, Suresh Kumar K, editors. Machine Learning Techniques for Diabetes Prediction: A Comparative Analysis. *International Conference on Sustainable Computing and Smart Systems, ICSCSS 2023 - Proceedings*; 2023.
133. Nagaraj P, Deepalakshmi P. An intelligent fuzzy inference rule-based expert recommendation system for predictive diabetes diagnosis. *International Journal of Imaging Systems and Technology*. 2022;32(4):1373-96.
134. Nagata M, Takai K, Yasuda K, Heracleous P, Yoneyama A, editors. Prediction Models for Risk of Type-2 Diabetes Using Health Claims. *BioNLP 2018 - SIGBioMed Workshop on Biomedical Natural Language Processing, Proceedings of the 17th BioNLP Workshop*; 2018.
135. Naik BD, Spoorthy A, Baherji S, Rout SK, Sethi BK, editors. Diabetes Prediction using Hybrid Machine Learning Techniques. *2024 OPJU International Technology Conference on Smart Computing for Innovation and Advancement in Industry 40, OTCON 2024*; 2024.
136. Nemade DR, Gupta RK, editors. Diabetes prediction using BPSO and decision tree classifier. *2nd International Conference on Data, Engineering and Applications, IDEA 2020*; 2020.
137. Nguyen BP, Pham HN, Tran H, Nghiem N, Nguyen QH, Do TTT, et al. Predicting the onset of type 2

- diabetes using wide and deep learning with electronic health records. *Computer Methods and Programs in Biomedicine*. 2019;182.
138. Nguyen HV, Choi Y, Byeon H. An explainable hybrid deep learning model for prediabetes prediction in men aged 30 and above. *Journal of Men's Health*. 2024;20(10):52-72.
 139. Nguyen LP, Tung DD, Nguyen DT, Le HN, Tran TQ, Binh TV, et al. The Utilization of Machine Learning Algorithms for Assisting Physicians in the Diagnosis of Diabetes. *Diagnostics*. 2023;13(12).
 140. Odedra D, Mallick M, Shukla P, Samanta S, Vidyarthi AS. Java-based diabetes type 2 prediction tool for better diagnosis. *Diabetes Technology and Therapeutics*. 2012;14(3):251-6.
 141. Odedra D, Samanta S, Vidyarthi AS. Computational intelligence-based diagnosis tool for the detection of prediabetes and type 2 diabetes in India. *The review of diabetic studies : RDS*. 2012;9(1):55-62.
 142. O'Grady KL, Viaña J, Cohen K, editors. Predicting Diabetes Diagnosis with Binary-To-Fuzzy Extrapolations and Weights Tuned via Genetic Algorithm. *Annual Conference of the North-American-Fuzzy-Information-Processing-Society (NAFIPS)*; 2021 Jun 07-09; Purdue Univ, ELECTR NETWORK2022.
 143. Olisah CC, Smith L, Smith M. Diabetes mellitus prediction and diagnosis from a data preprocessing and machine learning perspective. *Computer Methods and Programs in Biomedicine*. 2022;220.
 144. Omana J, Moorthi M. Predictive Analysis and Prognostic Approach of Diabetes Prediction with Machine Learning Techniques. *Wireless Personal Communications*. 2022;127(1):465-78.
 145. Omoora ES, Altaweil HA, Nagem T, Bozed KA, editors. Diabetes Mellitus Prediction Based on Machine Learning Techniques. *2023 IEEE 11th International Conference on Systems and Control, ICSC 2023*; 2023.
 146. Ozmen EP, Ozcan T. Diagnosis of diabetes mellitus using artificial neural network and classification and regression tree optimized with genetic algorithm. *Journal of Forecasting*. 2020;39(4):661-70.
 147. Ozturk B, Lawton T, Smith S, Habli I, editors. Balancing Acts: Tackling Data Imbalance in Machine Learning for Predicting Myocardial Infarction in Type 2 Diabetes. *Studies in Health Technology and Informatics*; 2024.
 148. Padmaraj R, Suresh D, Ravichandran S. NEIWDA with hybrid ensemble model for diagnosis of diabetes Type-II. *International Journal of Advanced Science and Technology*. 2020;29(3):5765-78.
 149. Palanisamy V, Mariamichael A. Diagnosis of Diabetes Mellitus by Extraction of Morphological Features of Red Blood Cells Using an Artificial Neural Network. *Experimental and Clinical Endocrinology & Diabetes*. 2016;124(9):548-56.
 150. Panwar M, Acharyya A, Shafik RA, Biswas D, editors. K-nearest neighbor based methodology for accurate diagnosis of diabetes mellitus. *Proceedings - 2016 6th International Symposium on Embedded Computing and System Design, ISED 2016*; 2017.
 151. Pathiranaage NJ, Asanka Sanjaya Suraweera SMD, editors. DiabetCare - A Classifier based Mobile Application for Predicting the Risk of Prediabetes Mellitus, Gestational Diabetes Mellitus and Type 2 Diabetes Mellitus. *Proceedings - International Research Conference on Smart Computing and Systems Engineering, SCSE 2024*; 2024.
 152. Pati A, Parhi M, Pattanayak BK, Barisal SK, Nayak G, editors. An Intelligent Diagnostic System for Type 2 Diabetes Mellitus. *Lecture Notes in Networks and Systems*; 2024.
 153. Patil R, Tamane S, Patil K, editors. An Experimental Approach Toward Type 2 Diabetes Diagnosis Using Cultural Algorithm. *Advances in Intelligent Systems and Computing*; 2021.
 154. Patil R, Tamane S, Rawandale SA, Patil K. A modified mayfly-SVM approach for early detection of type 2 diabetes mellitus. *International Journal of Electrical and Computer Engineering*. 2022;12(1):524-33.
 155. Patil RN, Rawandale S, Rawandale N, Rawandale U, Patil S. An efficient stacking based NSGA-II approach for predicting type 2 diabetes. *International Journal of Electrical and Computer Engineering*. 2023;13(1):1015-23.
 156. Pekel E, Özcan T. Diagnosis of diabetes mellitus using statistical methods and machine learning algorithms. *Sigma Journal of Engineering and Natural Sciences-Sigma Muhendislik Ve Fen Bilimleri Dergisi*. 2018;36(4):1263-80.
 157. Polat K, Günes S. An expert system approach based on principal component analysis and adaptive neuro-fuzzy inference system to diagnosis of diabetes disease. *Digital Signal Processing*. 2007;17(4):702-10.
 158. Preston FG, Meng Y, Burgess J, Ferdousi M, Azmi S, Petropoulos IN, et al. Artificial intelligence utilising corneal confocal microscopy for the diagnosis of peripheral neuropathy in diabetes mellitus and prediabetes. *Diabetologia*. 2022;65(3):457-66.
 159. Purnami SW, Zain JM, Embong A, editors. A New Expert System for Diabetes Disease Diagnosis Using Modified Spline Smooth Support Vector Machine. *International Conference on Computational Science and Its Applications*; 2010 Mar 20-28; Fukuoka, JAPAN2010.
 160. Rahman MA, Shoaib SM, Amin MA, Toma RN, Moni MA, Awal MA, editors. A Bayesian optimization framework for the prediction of diabetes mellitus. *2019 5th International Conference on Advances in Electrical Engineering, ICAEE 2019*; 2019.
 161. Rao BM, Hussain MA. EFASFMM: A Unique Approach for Early Prediction of Type II Diabetics using Fire Fly and Semi-supervised Min-Max Algorithm. *International Journal of Advanced Computer Science and Applications*. 2023;14(2):674-81.
 162. Rastogi R, Bansal M. Diabetes prediction model using data mining techniques. *Measurement: Sensors*. 2023;25.
 163. Rawat V, Joshi S, Gupta S, Singh DP, Singh N. Machine learning algorithms for early diagnosis of

- diabetes mellitus: A comparative study. *Materials Today: Proceedings*. 2022;56:502-6.
164. Rönn T, Perfilyev A, Oskolkov N, Ling C. Predicting type 2 diabetes via machine learning integration of multiple omics from human pancreatic islets. *Scientific Reports*. 2024;14(1).
165. Roy K, Ahmad M, Waqar K, Priyaah K, Nebhen J, Alshamrani SS, et al. An Enhanced Machine Learning Framework for Type 2 Diabetes Classification Using Imbalanced Data with Missing Values. *Complexity*. 2021;2021.
166. Sagir AM, Sathasivam S, editors. Design of a Modified Adaptive Neuro Fuzzy Inference System Classifier for Medical Diagnosis of Pima Indians Diabetes. *24th National Symposium on Mathematical Sciences (SKSM)*; 2017 Sep 27-29; Univ Malaysia Terengganu, Sch Informat & Appl Math, MALAYSIA2017.
167. Sai MJ, Chettri P, Panigrahi R, Garg A, Bhoi AK, Barsocchi P. An Ensemble of Light Gradient Boosting Machine and Adaptive Boosting for Prediction of Type-2 Diabetes. *International Journal of Computational Intelligence Systems*. 2023;16(1).
168. Sakhibgareeva MV, Zaozersky AY. Developing an artificial intelligence-based system for medical prediction. *Bulletin of Russian State Medical University*. 2017;6:40-4.
169. Salem H, Shams MY, Elzeki OM, Abd Elfattah M, Al-Amri JF, Elnazer S. Fine-Tuning Fuzzy KNN Classifier Based on Uncertainty Membership for the Medical Diagnosis of Diabetes. *Applied Sciences-Basel*. 2022;12(3).
170. Samant P, Agarwal R. Machine learning techniques for medical diagnosis of diabetes using iris images. *Computer Methods and Programs in Biomedicine*. 2018;157:121-8.
171. Samant P, Agarwal R. Analysis of computational techniques for diabetes diagnosis using the combination of iris-based features and physiological parameters. *Neural Computing and Applications*. 2019;31(12):8441-53.
172. Samreen S. Memory-Efficient, Accurate and Early Diagnosis of Diabetes Through a Machine Learning Pipeline Employing Crow Search-Based Feature Engineering and a Stacking Ensemble. *Ieee Access*. 2021;9:134335-54.
173. Sanchez-Brito M, Luna-Rosas FJ, Mendoza-Gonzalez R, Vazquez-Zapien GJ, Martinez-Romo JC, Mata-Miranda MM. Type 2 diabetes diagnosis assisted by machine learning techniques through the analysis of FTIR spectra of saliva. *Biomedical Signal Processing and Control*. 2021;69.
174. Saradha S, Sujatha P. Gestational Diabetes Diagnosis with MSVM, MJ48 Classifier Models. *International Journal of Recent Technology and Engineering*. 2019;8(2S11):244-8.
175. Sathishkumar P, Senthilraja P, Sri RA, Kabila R, editors. An Optimized Hybrid Machine Learning Algorithm for the Prediction of Type 2 Diabetes Mellitus. *2024 15th International Conference on Computing Communication and Networking Technologies, ICCCNT 2024*; 2024.
176. Sayadi M, Zibaeenezhad MJ, Ayatollahi SMT. Simple prediction of type 2 diabetes mellitus via decision tree modeling. *International Cardiovascular Research Journal*. 2017;11(2):71-6.
177. Sejdinović D, Gurbeta L, Badnjević A, Malenica M, Dujčić T, Čaušević A, et al., editors. Classification of prediabetes and type 2 diabetes using artificial neural network. *IFMBE Proceedings*; 2017.
178. Severeyn E, La Cruz A, Velásquez J, Huerta M, editors. Leveraging Support Vector Machines for Enhanced Diagnosis of Diabetes and Prediabetes. *2024 IEEE Colombian Conference on Communications and Computing, COLCOM 2024 - Proceedings*; 2024.
179. Severeyn E, Wong S, Velásquez J, Perpiñán G, Herrera H, Altuve M, et al., editors. Diagnosis of Type 2 Diabetes and Pre-diabetes Using Machine Learning. *8th Latin American Conference on Biomedical Engineering (CLAIB) / 42nd National Conference on Biomedical Engineering (CNIB)*; 2019 Oct 02-05; Cancun, MEXICO2020.
180. Severeyn E, Wong S, Velásquez J, Perpiñán G, Herrera H, Altuve M, et al., editors. Diagnosis of Type 2 Diabetes and Pre-diabetes Using Machine Learning. *IFMBE Proceedings*; 2020.
181. Shakhmametova G, Vakkazov N, Klimets S, editors. Predicting Threat Degree for Onset of Type 2 Diabetes Mellitus Based on Machine Learning Methods. *Lecture Notes in Networks and Systems*; 2023.
182. Shankar GS, Manikandan K. Diagnosis of diabetes diseases using optimized fuzzy rule set by grey wolf optimization. *Pattern Recognition Letters*. 2019;125:432-8.
183. Sharma K, Kachare PH, Sangle SB, Chudiwal R, Ieee, editors. Novel Composite feature fusion for Diabetes Diagnosis using Artificial Neural Network. *International Conference on Decision Aid Sciences and Applications (DASA)*; 2022 Mar 23-25; Chiangrai, THAILAND2022.
184. Shaikat Z, Zafar W, Ahmad W, Ul Haq I, Husnain G, Al-Adhaileh MH, et al. Revolutionizing Diabetes Diagnosis: Machine Learning Techniques Unleashed. *Healthcare*. 2023;11(21).
185. Shivakumar BL, Alby S, Ieee, editors. A Survey on Data-Mining Technologies for Prediction and Diagnosis of Diabetes. *International Conference on Intelligent Computing Applications (ICICA)*; 2014 Mar 06-07; Bharathiar Univ, Dept Comp Applicat, Coimbatore, INDIA2014.
186. Shrestha M, Alsadoon OH, Alsadoon A, Al-Dala'in T, Rashid TA, Prasad PWC, et al. A novel solution of deep learning for enhanced support vector machine for predicting the onset of type 2 diabetes. *Multimedia Tools and Applications*. 2023;82(4):6221-41.
187. Siahmarzkooh AT. ACO-based type 2 diabetes detection using artificial neural networks. *Indian Journal of Forensic Medicine and Toxicology*. 2021;15(1):1765-71.
188. Singh N, Singh P. Stacking-based multi-objective evolutionary ensemble framework for prediction of diabetes mellitus. *Biocybernetics and Biomedical Engineering*. 2020;40(1):1-22.

189. Singh P, Pal AB, Anburajan M, Kumar JS, editors. Computer-Aided Diagnosis of Type 2 Diabetes Mellitus Using Thermogram of Open Mouth. *Advances in Intelligent Systems and Computing*; 2018.
190. Singla J, Ieee, editors. Comparative Study of Mamdani-Type and Sugeno-Type Fuzzy Inference Systems for Diagnosis of Diabetes. *International Conference on Advances in Computer Engineering and Applications (ICACEA)*; 2015 Mar 19-20; Ghaziabad, INDIA2015.
191. Sonia JJ, Jayachandran P, Md AQ, Mohan S, Sivaraman AK, Tee KF. Machine-Learning-Based Diabetes Mellitus Risk Prediction Using Multi-Layer Neural Network No-Prop Algorithm. *Diagnostics*. 2023;13(4).
192. Spänig S, Emberger-Klein A, Sowa JP, Canbay A, Menrad K, Heider D. The virtual doctor: An interactive clinical-decision-support system based on deep learning for non-invasive prediction of diabetes. *Artificial Intelligence in Medicine*. 2019;100.
193. Srivastava AK, Kumar Y, Singh PK. Artificial Bee Colony and Deep Neural Network-Based Diagnostic Model for Improving the Prediction Accuracy of Diabetes. *International Journal of E-Health and Medical Communications*. 2021;12(2):32-50.
194. Sun Z, Yu SS, Zhang Y, Ieee, editors. An Optimal Decision Tree Model for Diabetes Diagnosis. *4th IEEE International Conference on Computational Intelligence and Applications (ICCI)*; 2019 Jun 21-23; Nanchang, PEOPLES R CHINA2019.
195. Suvartha M, Bhoomika S, Kalyan R, Nandan TM, Pavithra G, Manjunath TC, editors. Multi-Type Diabetes using Machine Learning - A New Method of Prediction & Determination. *15th International Conference on Advances in Computing, Control, and Telecommunication Technologies, ACT 2024*; 2024.
196. Tanim SA, Aurnob AR, Shrestha TE, Emon MRI, Mridha MF, Miah MSU. Explainable deep learning for diabetes diagnosis with DeepNetX2. *Biomedical Signal Processing and Control*. 2025;99.
197. Temiz M, Kuzudisli C, Yousef M, Bakir-Gungor B, editors. Prediction of Type 2 Diabetes using Metagenomic Data and Identification of Taxonomic Biomarkers. *32nd IEEE Conference on Signal Processing and Communications Applications, SIU 2024 - Proceedings*; 2024.
198. Tigga NP, Garg S, editors. Prediction of Type 2 Diabetes using Machine Learning Classification Methods. *Procedia Computer Science*; 2020.
199. Tigga NP, Garg S, editors. Predicting Type 2 Diabetes Using Logistic Regression. *Lecture Notes in Electrical Engineering*; 2021.
200. Tsiouras MG, Exarchos TP, Fotiadis DI, Ieee, editors. Automated creation of transparent fuzzy models based on decision trees - application to diabetes diagnosis. *30th Annual International Conference of the IEEE-Engineering-in-Medicine-and-Biology-Society*; 2008 Aug 20-24; Vancouver, CANADA2008.
201. Tuppad A, Devi Patil S. An efficient classification framework for Type 2 Diabetes incorporating feature interactions. *Expert Systems with Applications*. 2024;239.
202. Übeyli ED. Automatic diagnosis of diabetes using adaptive neuro-fuzzy inference systems. *Expert Systems*. 2010;27(4):259-66.
203. Venkatesan P, Anitha S. Application of a radial basis function neural network for diagnosis of diabetes mellitus. *Current Science*. 2006;91(9):1195-9.
204. Vijayan VV, Anjali C, Ieee, editors. Prediction and Diagnosis of Diabetes Mellitus -A Machine Learning Approach. *IEEE Recent Advances in Intelligent Computational Systems (RAICS)*; 2015 Dec 10-12; Trivandrum, INDIA2015.
205. Wang C, Zhang TM, Wang P, Liu X, Zheng LM, Miao L, et al. Bone metabolic biomarker-based diagnosis of type 2 diabetes osteoporosis by support vector machine. *Annals of Translational Medicine*. 2021;9(4).
206. Wang X, Shen P, Zhao G, Li J, Zhu Y, Li Y, et al. An enhanced machine learning algorithm for type 2 diabetes prognosis with a detailed examination of Key correlates. *Scientific Reports*. 2024;14(1).
207. Wardhani PK, Widiyanti P, Arisgraha FCS. Application of artificial neural network for type 2 diabetes mellitus detection using buccal cell images. *Journal of International Dental and Medical Research*. 2017;10(2):253-9.
208. Watomakin DB, Emanuel AWR, editors. Comparison of Performance Support Vector Machine Algorithm and Naive Bayes for Diabetes Diagnosis. *5th International Conference on Science in Information Technology (ICSITech)*; 2019 Oct 23-24; Univ Pembangunan Nasl Veteran Yogyakarta, Yogyakarta, INDONESIA2019.
209. Wood DA. Integrated statistical and machine learning analysis provides insight into key influencing symptoms for distinguishing early-onset type 2 diabetes. *Chronic Diseases and Translational Medicine*. 2022;8(4):281-95.
210. Wu H, Yang S, Huang Z, He J, Wang X. Type 2 diabetes mellitus prediction model based on data mining. *Informatics in Medicine Unlocked*. 2018;10:100-7.
211. Wu J, Diao YB, Li ML, Fang YP, Ma DC. A Semi-supervised Learning Based Method: Laplacian Support Vector Machine Used in Diabetes Disease Diagnosis. *Interdisciplinary Sciences-Computational Life Sciences*. 2009;1(2):151-5.
212. Wu LT, Luo XL, Xu Y. Using convolutional neural network for diabetes mellitus diagnosis based on tongue images. *Journal of Engineering-Joe*. 2020;2020(13):635-8.
213. Xie Z, Nikolayeva O, Luo J, Li D. Building risk prediction models for type 2 diabetes using machine learning techniques. *Preventing Chronic Disease*. 2019;16(9).
214. Xu Z, Wang Z, editors. A Risk prediction model for type 2 diabetes based on weighted feature selection of random forest and xgboost ensemble classifier. *11th International Conference on Advanced Computational Intelligence, ICACI 2019*; 2019.
215. Yang ZH, Zhou YH, Gong CX, Acm, editors. Diagnosis of Diabetes Based on Improved Support

- Vector Machine and Ensemble Learning. *3rd International Conference on Innovation in Artificial Intelligence (ICIAI)*; 2019 Mar 15-18; Suzhou, PEOPLES R CHINA 2019.
216. Yashar MM, Izci IB, Gungoren FZ, Eren AA, Mert AA, Durur-Subasi II. Can artificial intelligence detect type 2 diabetes in women by evaluating the pectoral muscle on tomosynthesis: diagnostic study. *Insights into Imaging*. 2024;15(1).
217. Yılmaz A. Prediction of type 2 diabetes mellitus using feature selection-based machine learning algorithms. *Health Problems of Civilization*. 2022;16(2):128-39.
218. Yin H, Jha NK. A Health Decision Support System for Disease Diagnosis Based on Wearable Medical Sensors and Machine Learning Ensembles. *IEEE Transactions on Multi-Scale Computing Systems*. 2017;3(4):228-41.
219. Zhang Z, Lu Y, Ye M, Huang W, Jin L, Zhang G, et al. A novel evolutionary ensemble prediction model using harmony search and stacking for diabetes diagnosis. *Journal of King Saud University - Computer and Information Sciences*. 2024;36(1).
220. Zhao J, Gao H, Yang C, An T, Kuang Z, Shi L. Attention-Oriented CNN Method for Type 2 Diabetes Prediction. *Applied Sciences (Switzerland)*. 2024;14(10).
221. Zhao M, Wan J, Qin WZ, Huang X, Chen GD, Zhao XY. A machine learning-based diagnosis modelling of type 2 diabetes mellitus with environmental metal exposure. *Computer Methods and Programs in Biomedicine*. 2023;235.
222. Zhou WH, Liu XM, Bai HT, He LL. Intelligent medical diagnosis and treatment for diabetes with deep convolutional fuzzy neural networks. *Information Sciences*. 2024;677.