



University of Qom

Provide a method to diagnose and optimize diabetes using data mining methods and firefly algorithm

Reza Molae Fard

MSC. Department of industrial engineering, Azad university of dezfull. Email: rezamolae4@gmail.com

Article Info	ABSTRACT
Article type: Research Article	Diabetes is one of the most common, dangerous and costly diseases in the world today, which is increasing at an alarming rate. The use of data mining methods can help in the early diagnosis of diabetes, which prevents the progression of this disease and many of its complications such as cardiovascular disease, vision problems and kidney disease. Providing care and health services to people with diabetes provides useful information that can be used to identify, treat, follow-up care and even prevent diabetes. In this study, a new method is presented to improve the diagnosis and prevention of diabetes using data mining methods. In this research, the DBSCAN clustering algorithm is used to cluster the data. Then, using SVM, we classify the data to identify useful data, and finally, with the firefly algorithm, we increase the obtained data to increase we optimize performance with this algorithm. The results of this study indicate that the DBSCAN algorithm is more efficient than other clustering algorithms. Also, the SVM algorithm can achieve 98% accuracy, which compared to other data mining algorithms could achieve a higher accuracy percentage.
Article history: Received 2023 March 23 Received in revised form 2023 May 27 Accepted 2023 May 20 Published online 2023 September 16	
Keywords: Data Mining, DBSCAN Algorithm, Diabetes Diagnosis, Firefly Algorithm, SVM Algorithm.	

Cite this article: Molae Fard, R. (2023). Provide a method to diagnose and optimize diabetes using data mining methods and firefly algorithm. *Enginiiring Management and Soft Computing*, 9 (1). 36-48. DOI: <https://doi.org/10.22091/JEMSC.2022.6575.1147>



© The Author(s)

DOI: <https://doi.org/10.22091/JEMSC.2022.6575.1147>

Publisher: University of Qom

ارائه روشی بهمنظور تشخیص و بهینه‌سازی بیماری دیابت با استفاده از روش‌های داده‌کاوی والگوریتم کرم شب‌تاب

رضا مولایی فرد 

کارشناس ارشد، دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی واحد دزفول. رایانه‌ام: rezamolae4@gmail.com

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	بیماری دیابت یکی از شایع‌ترین، خطرناک‌ترین و پرهزینه‌ترین بیماری‌های حال حاضر دنیاست که با نرخ هشداردهنده‌ای در حال افزایش است. استفاده از روش‌های داده‌کاوی می‌تواند به تشخیص زودهنگام دیابت کمک کند که باعث جلوگیری از پیشرفت این بیماری و خیلی از عوارض آن مانند بیماری‌های قلبی و عروقی، مشکلات بینایی و بیماری‌های کلیوی می‌شود. ارائه خدمات مراقبتی و بهداشتی افراد مبتلا به بیماری دیابت اطلاعات مفیدی ایجاد می‌کند که با استفاده از این اطلاعات می‌توان برای شناسایی، درمان، مراقبت‌های بعدی و حتی پیشگیری از بیماری دیابت استفاده نمود. در این تحقیق به ارائه روش جدیدی به منظور بهبود تشخیص و پیشگیری از بیماری دیابت با استفاده از روش‌های داده‌کاوی پرداخته می‌شود. در این تحقیق از الگوریتم خوشبندی DBSCAN جهت خوشبندی داده‌ها استفاده می‌شود سپس با استفاده از SVM، داده‌ها را جهت تشخیص داده‌های مفید، دسته‌بندی می‌کنیم و در نهایت با الگوریتم کرم شب‌تاب داده‌های بهدست آمده را جهت افزایش کارآیی با این الگوریتم بهینه می‌کنیم. نتایج حاصل از این تحقیق حاکی از کارآیی بالاتر الگوریتم DBSCAN نسبت به سایر الگوریتم‌های خوشبندی است. همچنین الگوریتم SVM می‌تواند دقت ۹۸ درصد را بهدست آورد که در مقایسه با سایر الگوریتم‌های داده‌کاوی توانست درصد دقت پیشتری را کسب کند.
تاریخ دریافت: ۱۴۰۲/۰۱/۰۳	کلیدواژه‌ها:
تاریخ بازنگری: ۱۴۰۲/۰۳/۰۶	الگوریتم کرم شب‌تاب، DBSCAN
تاریخ پذیرش: ۱۴۰۲/۰۳/۰۹	الگوریتم SVM، تشخیص دیابت، داده‌کاوی.
تاریخ انتشار: ۱۴۰۲/۰۶/۲۵	

استناد: فتحی هفتجانی، کیامرث؛ باقری سرخی، مجید و مدیری، محمود. (۱۴۰۲). «ارائه روشی بهمنظور تشخیص و بهینه‌سازی بیماری دیابت با استفاده از روش‌های داده‌کاوی والگوریتم کرم شب‌تاب». مهندسی و رایانش نرم، دوره ۹ (۱). صص: ۴۸-۳۶. <https://doi.org/10.22091/JEMSC.2022.6575.1147>



© نویسنده‌گان.

ناشر: دانشگاه قم

(۱) مقدمه

امروزه دیابت تبدیل به یک بیماری گسترده در سراسر دنیا شده است که میلیون‌ها نفر به آن مبتلا هستند. طبق آخرین آمارهای منتشر شده سازمان بهداشت جهانی و فدراسیون بین‌المللی دیابت، از هر ۴۰ نفر بالای ۶۰ سال یک نفر به این بیماری مبتلا می‌باشد. از این رو این بیماری به یکی از چالش‌های مهم نظام بهداشت و درمان کشورهای مختلف تبدیل شده است. عدم تشخیص به موقع و یا ضعف در تشخیص این بیماری از جمله مشکلات عمدۀ دیگری است که در رابطه با این بیماری وجود دارد. این امر تا حد زیادی به دلیل عدم انتخاب الگوی مناسب توسط پزشک یا عدم استفاده از الگوهای استاندارد موجود است. بنابراین پیاده‌سازی روشی که بتواند هر فرد را در تشخیص صحیح ابتلا یا عدم ابتلا به این بیماری یاری رساند، می‌تواند گام مهمی در جهت پیشگیری و کنترل این بیماری بخصوص در مراحل ابتدایی آن تلقی گردد. بیماری دیابت یکی از شایع‌ترین، خطرناک‌ترین و پرهزینه‌ترین بیماری‌های حال حاضر دنیاست که با نرخ هشداردهنده‌ای در حال افزایش است. استفاده از روش‌های داده‌کاوی می‌تواند به تشخیص زودهنگام دیابت کمک کند که باعث جلوگیری از پیشرفت این بیماری و خیلی از عواض آن مانند بیماری‌های قلبی و عروقی، مشکلات بینایی و بیماری‌های کلیوی می‌شود. ارائه خدمات مراقبتی و بهداشتی افراد مبتلا به بیماری دیابت اطلاعات مفیدی ایجاد می‌کند که با استفاده از این اطلاعات می‌توان برای شناسایی، درمان، مراقبت‌های بعدی و حتی پیشگیری از بیماری دیابت استفاده نمود. از طرفی کاوش و بررسی حجم زیادی از این اطلاعات، نیازمند استفاده از روش‌های مؤثر و کارآمدی برای یافته الگوهای مربوط در این اطلاعات است که استفاده از تکنیک‌های مختلف داده‌کاوی بخصوص دسته‌بندی و الگوهای تکرارشونده می‌تواند کمک بسیار زیادی در این زمینه باشد. آنچه مسلم است با افزایش سیستم‌های الکترونیک سلامت، حجم داده‌های پزشکی روزبه‌روز در حال افزایش است. اما این مجموعه داده‌های بزرگ به‌طور خام هیچ کاربردی ندارند. برای آنکه بتوان از این داده‌ها، اطلاعات مفیدی استخراج کرد، نیاز به تحلیل داده‌ها و تبدیل این اطلاعات به اطلاعات مفید است. با توجه به حجم بالای اطلاعات، استفاده از عامل انسانی به عنوان تشخیص‌دهنده الگو و تحلیلگر داده‌ها پاسخگو نمی‌باشد لذا داده‌کاوی روی داده‌های پزشکی از اهمیت بالایی برخوردار است. داده‌کاوی را می‌توان از جنبه‌های مختلف در پیشگیری یا تشخیص انواع بیماری، انتخاب روش‌های درمان و مدت زمان بسته‌یار بکار برد. داده‌کاوی برای بررسی داده‌های زیاد و استخراج ویژگی‌ها از میان حجم انبوه اطلاعات مورد استفاده قرار می‌گیرد. از بین الگوریتم‌های داده‌کاوی، الگوریتم‌های دسته‌بندی بهترین کارآیی را در بین این الگوریتم‌ها دارا می‌باشند زیرا در این الگوریتم‌ها نمونه‌ها دارای برچسب کلاس هستند و هدف از تعیین برچسب کلاس، ایجاد یک نمونه جدید می‌باشد. داده‌کاوی روشنی برای کشف الگوهای پنهان و استخراج اطلاعات معنی دار از مجموعه داده‌های بزرگ است. در واقع داده‌کاوی بخشی از فرآیند استخراج دانش است که هدف آن دستیابی به دانش نهفته در داده‌ها با کمترین دخالت انسانی است. در سال‌های اخیر تحقیقات زیادی در زمینه پیشگیری و درمان بیماری دیابت صورت گرفته است. در این تحقیق نیز با بهره‌گیری از روش‌های پیشین به ارائه روش جدیدی به منظور بهبود و پیشگیری درمان بیماری دیابت پرداخته می‌شود که با رفع ایرادات روش‌های قبلی، سیستم پیشنهادی می‌تواند نتایج دقیق‌تری کسب کند.

(۲) کارهای پیشین

پراسد و همکاران در مقاله خود در سال ۲۰۲۰ به ارائه روشی بهمنظور بهبود تشخیص دیابت با استفاده از الگوریتم‌های داده کاوی پرداختند. این محققان برای تشخیص و پیشگیری بیماری دیابت از چهار نوع الگوریتم داده کاوی استفاده کردند. این الگوریتم‌ها برای استفاده در مجموعه‌های آموزشی و آزمایشی و تولید جزئیات پیش‌بینی استفاده شده‌است. این الگوریتم‌ها با استفاده از معیارهایی مانند دقت، میانگین قدر مطلق خطأ (MAE) و میانگین مربع خطای نقاط (RMSE) ارزیابی شدند. نتایج حاصل از تحقیق نشان داد که همه الگوریتم‌های یادگیری ماشین قادر به پیش‌بینی بیماری‌ها خواهند بود. با این حال؛ آنها از نظر سطح دقت متفاوت هستند. طبق تحقیقات صورت گرفته، جنگل تصادفی بالاترین دقت را در بین این الگوریتم‌ها داشته‌است و این الگوریتم می‌تواند پیش‌بینی دقیقی از تشخیص انواع بیماری‌ها داشته باشد [۱].

کازرونی و همکاران در مقاله خود در سال ۲۰۲۰ به یافتن و مقایسه روش‌های استخراج و پیش‌بینی اطلاعات مربوط به بیماری دیابت با استفاده از روش‌های داده کاوی پرداختند. این محققان به ارزیابی ۶ مورد از ابزارهای داده کاوی برای پیش‌بینی بیماری دیابت پرداختند که هدف از این ارزیابی و مقایسه، یافتن بهترین روش استخراج داده برای پیش‌بینی T2DM با استفاده از روش‌های داده کاوی بود. نتایج حاصل از تحقیق حاکی از میزان بالای AUC اختصاص داده شده به SVM و رگرسیون لجستیک و همچنین دو الگوریتم KNN و ANN بیشترین حساسیت متوسط و بیشترین ویژگی‌های تشخیص را نسبت به سایر الگوریتم‌های موجود دارا می‌باشد [۲].

کومار و همکاران در مقاله خود در سال ۲۰۲۰ به بررسی روش‌های داده کاوی برای پیش‌بینی بیمارها پرداختند. این محققان بر این عقیده هستند که روش‌های داده کاوی برای تشخیص بیماری‌ها دارای اهمیت زیادی هستند و بر کسی پوشیده نیست که این اطلاعات می‌تواند برای متخصصان مراقبت‌های بهداشتی و درمان جهت اهداف مختلف مورد استفاده قرار گیرد. این محققان هدف از مقاله خود را ارزیابی و تجزیه و تحلیل داده‌ها با استفاده از سه روش منحصر به فرد Naïve Bayes Support Vector Machine (SVM)، (NB) و درخت تصمیم قرار دادند و همچنین برای تصمیم‌گیری رویکردهای بالقوه برای پیش‌بینی احتمال بیماری قلبی برای دیابتی‌ها بیماران وابسته به دقت پیش‌بینی آنها هستند [۳].

علیرضایی و همکاران در مقاله خود در سال ۲۰۱۹ به ارائه روشی بهمنظور پیشگیری از بیماری دیابت با استفاده از الگوریتم‌های فرابتکاری پرداختند. این محققان در مقاله خود از روشی مبتنی بر الگوریتم خوشبندی k-means شناسایی و حذف نقاط دور استفاده کردند. سپس بهمنظور انتخاب ویژگی‌های قابل توجه با بالاترین دقت طبقه‌بندی با استفاده از ماشین‌های بردار پشتیبانی (SVM) استفاده نمودند. علاوه بر این؛ برای اعتبارسنجی مدل ساخته شده از روش اعتباردهی ضربدری ۱۰ برابر (CV) استفاده کردند. نتایج حاصل از این تحقیق حاکی از آن بود که الگوریتم کرم شب تاب چندهدفه (MOFA) و الگوریتم رقابتی امپریالیستی چندهدفه (MOICA) با دقت طبقه‌بندی ۱۰۰ درصد از الگوریتم ژنتیک مرتب‌سازی غیرسلطه (NSGA-II) و چندهدفه پیشی می‌گیرند و بهینه‌سازی از دحام ذرات (MOPSO) دقت ۹۴/۶ درصد را به دست آورده [۴].


کاثور وشارما در مقاله خود در سال ۲۰۱۸ به بررسی روش‌های پیشگیری و درمان بیماری دیابت با استفاده از ابزارهای داده کاوی پرداختند. این محققان از الگوریتم ژنتیک برای پیش‌بینی و پیشگیری از بیماری دیابت استفاده کردند. این

محققان در تحقیقات خود به این نکته پی‌بردند که استفاده از ابزارهای داده‌کاوی ۷۴ تا ۱۰۰ درصد می‌تواند به بهبود بیماری دیابت کمک نماید. روش کار این محققان استفاده از یک روش فرابتکاری ترکیبی با استفاده از دو الگوریتم ژنتیک و الگوریتم بهینه‌سازی ذرات بود. نتایج حاصل از این تحقیق حاکی از دقت ۸۷ درصدی روش پیشنهادی بود که می‌تواند تا حدود زیادی به فرآیند تشخیص بیماری دیابت کمک نماید [۵].

بریک و همکاران در مقاله خود در سال ۲۰۲۱ به بررسی ابزارهای مفید داده‌کاوی برای پیشگیری و درمان بیماری دیابت پرداختند. بررسی این محققان نشان می‌دهد که حدود ۳۴۷ میلیون نفر از جمعیت جهان تحت تأثیر دیابت قرار دارند. دیابت نه تنها در فرد مسن بلکه بر روی نسل جوان نیز تأثیر می‌گذارد. تشخیص دیابت در مراحل اولیه نیز یک چالش بزرگ است. این تشخیص برای روند تصمیم‌گیری سیستم پزشکی مفید خواهد بود. پیش‌بینی اولیه دیابت به ما کمک می‌کند تا زندگی انسان را از دیابت نجات دهیم. طولانی شدن دیابت منجر به خطر آسیب در اندام‌های حیاتی بدن انسان می‌شود. بنابراین پیش‌بینی اولیه دیابت برای نجات انسان از دیابت بسیار مهم است. در این مقاله دو مجموعه از روش یادگیری ماشین برای پیش‌بینی دیابت ارائه شده است. یکی از آنها الگوریتم مبتنی بر طبقه‌بندی و دیگری الگوریتم ترکیبی است. در طبقه‌بندی، الگوریتم جنگل تصادفی مورد استفاده قرار گرفته است. برای رویکرد ترکیبی نیز، الگوریتم XGBoost استفاده شده است. این دو الگوریتم بهمنظور بررسی دقت پیش‌بینی در دیابت برای دو روش یادگیری ماشین مختلف اجرا و مقایسه شدند و میانگین نمره ۷۴/۱۰ را کسب کردند که از الگوریتم Random Forest بهتر است [۶].

۳) روش پیشنهادی

در روش پیشنهادی به ارائه روش جدیدی بهمنظور شناسایی، تشخیص و پیشگیری بیماری دیابت با استفاده از روش‌های داده‌کاوی پرداخته می‌شود. روش پیشنهادی بدین صورت می‌باشد که در ابتدا اطلاعات مربوط به بیماران را جمع‌آوری می‌کنیم. سپس برای این که دقت اطلاعات را از جهات مختلف بالا ببریم عملیات پیش‌پردازش داده‌ها را روی داده‌ها انجام می‌دهیم. عملیات داده‌کاوی از آن جهت مورد استفاده قرار می‌گیرد که داده‌های خام را نمی‌توان به‌طور مستقیم به ابزارهای داده‌کاوی تزریق کرد. در مراحل بعد و پس از پیش‌پردازش داده‌ای باید عملیات خوشه‌بندی را بر روی داده‌ها مورد استفاده قرار دهیم. روش خوشه‌بندی موردنظر استفاده از الگوریتم خوشه‌بندی DBSCAN می‌باشد. خوشه‌بندی داده بهمنظور یافتن بیشترین شباهت میان داده‌ها مورد استفاده قرار می‌گیرد. در مرحله بعد باید داده‌های به‌دست آمده از مراحل قبل را جهت تشخیص داده‌ها با استفاده از ماشین‌بردار پشتیبان دسته‌بندی کنیم و در مرحله آخر نیز جهت بهینه‌سازی و بهبود اطلاعات، داده‌ها را با استفاده از الگوریتم کرم شب تاب، بهینه می‌کنیم تا کارآیی الگوریتم به بالاترین حد خود برسد و در نهایت به ارزیابی داده‌ها می‌پردازیم.



شکل ۱. نمایی از روش پیشنهادی

(۳) جمع‌آوری داده‌ها

برای شروع بکار و پیاده‌سازی روش پیشنهادی ابتدا باید پایگاه داده‌ای از لیست افراد مبتلا به بیماری دیابت و علائم این افراد را داشته باشیم تا بتوانیم روش پیشنهادی را پیاده‌سازی کنیم. برای انجام این کار یک فایل شامل اطلاعات ۸۰۴ بیمار را جمع‌آوری کردیم. بعد از جمع‌آوری اطلاعات مربوط به بیماران، کار را بر روی این داده‌ها آغاز کردیم.

(۴) پیش‌پردازش داده‌ها

پس از مرحله جمع‌آوری داده‌ها باید عملیات پیش‌پردازش داده‌ها را بر روی داده‌ها انجام دهیم. در فرآیند داده‌کاوی نیاز

داریم تا داده‌ها برای الگوریتم آماده شوند زیرا معمولاً نمی‌توان داده‌ها را به صورت خام به الگوریتم‌های داده‌کاوی و یادگیری ماشین تزریق کرد. برای آماده‌سازی داده‌ها نیاز است تا آنها را از شکل و حالت اولیه خارج کرده و به شکلی که برای الگوریتم مناسب باشد، تبدیل کرد. همچنین داده‌های موجود معمولاً دارای زواید مختلفی هستند که ممکن است الگوریتم را دچار خطا کنند [8, 7]. در داده‌کاوی نیاز داریم تا داده‌های اضافی را که به مسئله و الگوریتم کمکی نمی‌کنند، حذف کنیم. عملیات پیش‌پردازش داده‌ها معمولاً قبل از عملیات اصلی الگوریتم‌های داده‌کاوی انجام می‌گیرند و باعث تسهیل و کمک به الگوریتم‌ها می‌شوند [9].

(۶) پاکسازی داده‌ها

در این مرحله باید داده‌های موجود را پاکسازی کنیم. پاکسازی داده‌ها فرآیند از بین بردن خطاهای ناسازگاری‌ها در داده‌های سیستم و در واقع مرحله کنترل کیفی قبل از انجام تحلیل داده‌ها می‌باشد. اغلب به جهت خطاهای عملیاتی و پیاده‌سازی سیستم‌ها، داده‌های برآمده از منابع دنیای واقعی پرغلط، ناقص و ناسازگار هستند. لازم است در ابتدا چنین داده‌هایی تمیز شوند. این کار شامل برخی عملیات پایه مانند نرمال‌سازی، حذف نویز یا اغتشاش، مواجهه با داده‌های مفقوده، کاهش افزونگی و برطرف کردن داده‌های متضاد باشد.

(۷) نرمال‌سازی داده‌ها

پس از پیش‌پردازش داده‌ها، باید داده‌ها را نرمال کنیم. در نرمال‌سازی داده‌ها، تغییر داده‌ها به گونه‌ای است که آنها را به یک دامنه کوچک و معین مانند فاصله بین ۰ و ۱ نگاشت کنند. هدف نرمال‌سازی حذف افزونگی داده و باقی نگهداشتن وابستگی بین داده‌های مرتبط می‌باشد. این فرآیند اغلب باعث ایجاد جداول بیشتر می‌شود ولی اندازه‌گیری پایگاه داده را کاهش داده و بهبود کارآیی را تضمین می‌کند. روش‌های مختلفی جهت نرمال‌سازی داده‌ها وجود دارد که معروف‌ترین آنها می‌توان به روش Min – Max Normalization اشاره کرد. در این روش هر کدام از داده‌ها را می‌توان به یک بازه دلخواه تبدیل کرد. فرمول کلی این روش برای تبدیل داده‌ها به بازه بین ۰ تا ۱ به صورت زیر می‌باشد:

$$z = \frac{x - \min(x)}{\max(x) - \min} \quad (1)$$


(۸) خوشبندی داده‌ها با الگوریتم DBSCAN

پس از پیش‌پردازش داده‌ها باید عملیات خوشبندی داده‌ها را انجام دهیم. خوشبندی از آن جهت مورد استفاده قرار خواهد گرفت که ما بتوانیم شباهت بین داده‌ها را پیدا کنیم. روش خوشبندی موردنظر الگوریتم خوشبندی DBSCAN می‌باشد که در بین الگوریتم‌های خوشبندی موجود بالاترین میزان کارآیی را دارد. روش کار الگوریتم DBSCAN به این صورت می‌باشد که در این الگوریتم دو پارامتر وجود دارد. یکی از این پارامترها شاعع است که به آن Epsilon می‌گویند و دومین پارامتر، حداقل نقاط موجود در یک خوشه است که به آن Min point می‌گویند [10]. این الگوریتم ابتدا یک نمونه را انتخاب می‌کند و با توجه به شاعع Epsilon به دنبال همسایه برای این نقطه در فضای می‌گردد. اگر الگوریتم در آن شاعع مشخص Epsilon حداقل توانست به تعداد Min point نقطه پیدا کند، آنگاه همه آن نقاط با هم به یک خوشه

تعلق می‌گیرند. الگوریتم سپس به دنبال یکی از نقطه‌های هم‌جوار نقطه فعلی می‌رود تا دوباره با شعاع Epsilon در آن نقطه به دنبال نقاط همسایه بگردد و اگر باز هم تعداد نقاط همسایه جدید پیدا شوند، این الگوریتم دوباره همه آن نقاط جدید را با نقاط قبلی به یک خوش‌هش تعلق می‌دهد و اگر نقطه جدیدی در همسایگی پیدا نکرد این خوش‌هش تمام شده است و برای پیدا کردن خوش‌های دیگر در نقاط دیگر به صورت تصادفی یک نقطه دیگر را انتخاب کرده و شروع به یافتن همسایه و تشکیل خوش‌هش جدید برای آن نقطه می‌کند. این کار آنقدر ادامه پیدا می‌کند تا تمام نقاط بررسی شوند [11, 12].

۹) تشخیص و دسته‌بندی داده‌ها با SVM

در مرحله بعد باید داده‌های خود را جهت تشخیص نمونه‌های سالم و نمونه‌های بیمار دسته‌بندی کنیم. روش پیشنهادی موردنظر استفاده از الگوریتم SVM می‌باشد که می‌تواند دسته‌بندی دقیقی را بر روی داده‌ها انجام دهد. در روش ماشین‌بردار پشتیبان، بردارهای ورودی به یک فضای چندبعدی نگاشت می‌شوند. پس از آن، یک ابرسطح ساخته خواهد شد که با حداقل فاصله ممکن، بردارهای ورودی را از هم جدا خواهد کرد [13]. به این ابرسطح، ابرسطح با حداقل مرز جداکننده گفته می‌شود. همانگونه که در شکل ۲ نشان داده شده است، دو ابرسطح موازی در دو سمت ابرسطح با حداقل مرز جداکننده ساخته خواهد شد که داده‌های مربوط به دو طبقه را به گونه‌ای از هم مجزا می‌کنند که هیچ داده‌ای در مرز بین این دو ابرسطح قرار نمی‌گیرد. ابرسطح با حداقل مرز جداکننده، ابرسطحی است که فاصله بین دو ابرسطح موازی را به حداقل می‌رساند [14, 15]. فرض بر این است که هر چقدر مرز جداکننده یا درواقع فاصله بین دو ابرسطح موازی بیشتر باشد، خطای طبقه‌بندی هم کمتر خواهد بود. در پایان این مرحله، داده‌ها دسته‌بندی و به دو طبقه مجزا تقسیم می‌شوند که از طریق این تقسیم‌بندی می‌توان داده‌ها را جهت داده‌های صحیح و غیر صحیح تقسیم نمود.



شکل ۲. نحوه ساخت ابرسطح جداکننده بین دو طبقه داده در فضای دو بعدی

(۱۰) بینه‌سازی داده‌ها با الگوریتم کرم شب تاب


در این مرحله باید با استفاده از الگوریتم کرم شب تاب داده‌های خود را بینه‌کنیم. ایده الگوریتم کرم شب تاب از ارتباط نوری میان کرم‌های شب تاب الهام گرفته شده است [۱۶]. این الگوریتم را می‌توان از مظاهر هوش ازدحامی دانست که در آن از همکاری و احتمالاً رقابت اعضای ساده و کم‌هوش، مرتبه بالاتری از هوشمندی ایجاد می‌شود که قطعاً توسط هیچ یک از اجزا قابل حساب نیست. این الگوریتم یک الگوریتم هوش جمعی است [۱۷]. هر فرد (که در این الگوریتم کرم شب تاب نامیده می‌شود) در جمعیت بینگر یک راه حل بالقوه در یک فضای چندبعدی است [۱۸]. به دلیل قدرت جذب بین کرم‌های شب تاب، آنها به سمت بقیه مکان‌ها حرکت می‌کنند تا راه حل‌های بهتری را بیابند [۱۹, ۲۰]. در الگوریتم کرم شب تاب، میزان جاذب بودن براساس قدرت تابش نور و روشنایی آن فرد تعیین می‌شود. این میزان در اصل متناسب با میزان شایستگی یک فرد است. یک مسئله پیدا کردن بینه است. برای کرم شب تاب x ، ارتباط میان شایستگی و میزان تابش نور و روشنایی آن کرم می‌تواند به صورت $f(x) \propto I(x)$ بیان شود. میزان جاذب بودن که با β نشان داده می‌شود، متناسب با α خواهد بود. با افزایش این فاصله، میزان جاذب بودن به تدریج کاهش خواهد یافت [۲۱]. درنظر بگیرید که X_i بینگر ۱ امین فرد در جمعیت باشد، در این صورت میزان جاذب بودن فرد ۱ام توسط فرد ۱ام با استفاده از رابطه زیر بیان خواهد شد.

$$\beta(r_{ij}) = \beta_0 e^{-r_{ij}^2} \quad \text{where } r_{ij} = \|X_i - X_j\| \quad (2)$$

که در آن $\|X_j - X_i\|$ فاصله اقلیدسی دو کرم شب تاب ۱ و ۰ میزان جاذب بودن در فاصله صفر را بیان می‌کند. γ نیز ضریب جذب نور را بیان می‌کند. بهترین مقدار برای γ برابر $\frac{1}{r^2}$ است که در آن α مقیاس طول برای متغیرهای طراحی شده خواهد بود. برای هر کرم شب تاب X_i در مقایسه با کرم X_j اگر X_j روشنایی بیشتری نسبت به X_i براساس میزان جاذب بودن X_j به سمت X_j حرکت خواهد کرد. میزان این حرکت براساس معادله زیر به دست می‌آید.

$$x_{id}(t+1) = x_{id}(t) + \beta_0 e^{-r_{ij}^2} (x_{jd}(t) - x_{id}(t)) + a\epsilon_i \quad (3)$$

که در آن، x_{id} مولفه d ام فرد i ام در جمعیت، a بعد راه حل، α ضریب اهمیت به حرکت تصادفی، ϵ_i یک عدد تصادفی و t شاره نسل می‌باشند. چهارچوب الگوریتم کرم شب تاب را در شکل زیر مشاهده می‌کنید.




شکل ۳. چهار چوب الگوریتم کرم شب تاب

(۱۱) ارزیابی روش پیشنهادی

برای ارزیابی روش پیشنهادی ابتدا مقایسه‌ای بین الگوریتم خوشبندی DBSCAN و سایر روش‌های خوشبندی از لحاظ میزان کارآیی صورت گرفت. سپس مقایسه‌ای بین الگوریتم SVM و سایر الگوریتم‌های دسته‌بندی از لحاظ میزان دقیق‌تر گرفت و در نهایت نیز الگوریتم کرم شب تاب با سایر الگوریتم‌های بهینه‌سازی مقایسه گردید که نتایج حاصل از ارزیابی روش پیشنهادی را در نمودارهای زیر می‌توان مشاهده نمود. به منظور ارزیابی میزان کارآیی الگوریتم DBSCAN مقایسه‌ای بین این الگوریتم و دو الگوریتم k-means و c-means صورت گرفت که نتایج حاصل از ارزیابی حاکی از عملکرد بهتر الگوریتم استفاده شده در روش پیشنهادی تحقیق بود. در این ارزیابی الگوریتم DBSCAN توانست میزان کارآیی ۹۶ درصد را به دست آورد. این در حالی بود که الگوریتم k-means، کارآیی ۷۶ درصد و الگوریتم c-means کارآیی ۵۵ درصد را به دست آورد که نتایج حاصل از این ارزیابی را می‌توان در جدول زیر مشاهده نمود.

جدول ۱. ارزیابی میزان کارآیی الگوریتم DBSCAN با سایر روش‌های خوشبندی

نام الگوریتم	میزان کارآیی
K-Means	76 درصد
C-Means	55 درصد
DBSCAN	96 درصد




شکل ۴. مقایسه میزان کارآبی الگوریتم خوشه‌بندی DBSCAN با دو الگوریتم C-means و K-means

به منظور ارزیابی میزان دقต الگوریتم SVM نیز مقایسه‌ای بین این الگوریتم و الگوریتم‌های KNN و MLP صورت گرفت. نتایج حاصل از این ارزیابی حاکی از درصد دقت بالاتر الگوریتم SVM بود. به این صورت که الگوریتم SVM توانست میزان دقت ۹۸ درصد را به دست آورد در حالیکه الگوریتم KNN دقت ۹۰ درصد و الگوریتم MLP میزان دقت ۹۶ درصد را به دست آورد. نتایج حاصل از این مقایسه را در جدول زیر مشاهده می‌کنید.

جدول ۲. ارزیابی میزان دقت روش پیشنهادی و سایر روش‌ها

نام الگوریتم	میزان دقت
SVM	۹۸ درصد
KNN	۹۰ درصد
MLP	۹۶ درصد




شکل ۵. مقایسه میزان دقت الگوریتم SVM با دو الگوریتم KNN و MLP

به منظور ارزیابی میزان روش‌های بهینه‌سازی نیز مقایسه‌ای بین الگوریتم کرم شب تاب و الگوریتم‌های PSO و الگوریتم گرگ خاکستری صورت گرفت. نتایج حاصل از میزان ارزیابی قسمت بهینه‌سازی حاکی از میزان بهینه‌سازی بالاتر الگوریتم کرم شب تاب بود تا جایی که الگوریتم کرم شب تاب توانست میزان دقت ۹۵ درصد و الگوریتم PSO دقت

۸۵ درصد و الگوریتم گرگ خاکستری دقت ۹۰ درصد را به دست آورد. نتایج حاصل از این مقایسه را در جدول زیر مشاهده می کنید.

جدول ۳. ارزیابی و مقایسه میزان بهینه سازی الگوریتم کرم شب تاب و سایر روش ها

نام الگوریتم	میزان دقت روش بهینه سازی
PSO	۸۵ درصد
الگوریتم گرگ خاکستری	۹۰ درصد
الگوریتم کرم شب تاب	۹۵ درصد



شکل ۶. مقایسه الگوریتم کرم شب تاب و دو الگوریتم PSO و الگوریتم گرگ خاکستری

(۱۲) نتیجه گیری

داده کاوی روی داده های پژوهشی از اهمیت بالایی برخوردار است. داده کاوی را می توان از جنبه های مختلف در پیشگیری یا تشخیص انواع بیماری، انتخاب روش های درمان و مدت زمان بستری بیمار بکار برد. داده کاوی برای بررسی داده های زیاد و استخراج ویژگی ها از میان حجم انبوه اطلاعات مورد استفاده قرار می گیرد. از بین الگوریتم های داده کاوی، الگوریتم های دسته بندی بهترین کارآیی را در بین این الگوریتم ها دارا می باشند زیرا در این الگوریتم ها، نمونه های دارای برچسب کلاس هستند و هدف از تعیین برچسب کلاس، ایجاد یک نمونه جدید می باشد. داده کاوی روشی برای کشف الگوهای پنهان و استخراج اطلاعات معنی دار از مجموعه داده های بزرگ است. در این نوع از مطالعات، متغیرهای فیزیکی و خونی عده ای از بیماران دیابتی و افراد معمولی به الگوریتم های دسته بندی در داده کاوی داده می شود. این الگوریتم ها می توانند مدل هایی را برای رده بندی بیماران به دو رده بیمار دیابتی و افراد سالم ایجاد نمایند. از مدل های ایجاد شده می توان به منظور رده بندی مراجعین جدید و افراد مشکوک به بیماری دیابتی و افراد سالم ایجاد نماید. از سلامت افراد جدید را پیش بینی کرد. در این تحقیق سعی کردیم که با استفاده از الگوریتم های داده کاوی به پیش بینی و تشخیص بیماری دیابت کمک کنیم. نتایج حاصل از تحقیق حاکی از آن است که روش پیشنهادی موجود در این تحقیق می تواند تا بیش از ۹۸ درصد به درستی بیماری را تشخیص داده و توانسته دقت بیشتری را نسبت به سایر الگوریتم های موجود به دست آوریم.

منابع

- Alirezaei, M., Niaki, S. T. A., & Niaki, S. A. A. (2019). A bi-objective hybrid optimization algorithm to reduce noise and data dimension in diabetes diagnosis using support vector machines. *Expert Systems with Applications*, 127, 47-57. <https://doi.org/10.1016/j.eswa.2017.04.003>
- Barik, S., Mohanty, S., Mohanty, S., & Singh, D. (2021). Analysis of prediction accuracy of diabetes using classifier and hybrid machine learning techniques. In *Intelligent and Cloud Computing* (pp. 399-409). Springer, Singapore. https://doi.org/10.1007/978-981-16-4545-4_35
- Dey, N. (2020). *Applications of firefly algorithm and its variants*. Springer Singapore. https://doi.org/10.1007/978-981-16-2030-3_113
- Gopi, A. P., Jyothi, R. N. S., Narayana, V. L., & Sandeep, K. S. (2020). Classification of tweets data based on polarity using improved RBF kernel of SVM. *International Journal of Information Technology*, 1-16. <https://doi.org/10.1007/s40222-022-02012-w>
- Kaur, P., & Sharma, M. (2018). Analysis of data mining and soft computing techniques in prospecting diabetes disorder in human beings: a review. *Int. J. Pharm. Sci. Res.*, 9, 2700-2719. <https://doi.org/10.1093/ijpr/2017.22.63>
- Kazerouni, F., Bayani, A., Asadi, F., Saeidi, L., Parvizi, N., & Mansoori, Z. (2020). Type2 diabetes mellitus prediction using data mining algorithms based on the long-noncoding RNAs expression: a comparison of four data mining approaches. *BMC bioinformatics*, 21(1), 1-13. <https://doi.org/10.1186/s13073-019-0713-0>
- Kouziokas, G. N. (2020). SVM kernel based on particle swarm optimized vector and Bayesian optimized SVM in atmospheric particulate matter forecasting. *Applied Soft Computing*, 93, 106410. <https://doi.org/10.1016/j.asoc.2020.106410>
- Kumar, A., Kumar, P., Srivastava, A., Kumar, V. A., Vengatesan, K., & Singhal, A. (2020, April). Comparative Analysis of Data Mining Techniques to Predict Heart Disease for Diabetic Patients. In *International Conference on Advances in Computing and Data Sciences* (pp. 507-518). Springer, Singapore. https://doi.org/10.1007/978-981-16-2351-4_49
- Li, Z., Li, Y., Lu, W., & Huang, J. (2020). Crowdsourcing logistics pricing optimization model based on DBSCAN clustering algorithm. *IEEE Access*, 8, 92615-92626. <https://doi.org/10.1109/ACCESS.2020.2971111>
- Luengo, J., García-Gil, D., Ramírez-Gallego, S., García, S., & Herrera, F. (2020). *Big data preprocessing*. Cham: Springer. <https://doi.org/10.1007/978-3-030-13566-6>
- Marie-Sainte, S. L., & Alalyani, N. (2020). Firefly algorithm based feature selection for Arabic text classification. *Journal of King Saud University-Computer and Information Sciences*, 32(3), 320-328. <https://doi.org/10.1016/j.jksusci.2015.08.025>
- Manikannan, K., & Nagarajan, V. (2020). Optimized mobility management for RPL/6LoWPAN based IoT network architecture using the firefly algorithm. *Microprocessors and Microsystems*, 77, 103193. <https://doi.org/10.1016/j.micpro.2020.103193>
- Mishra, P., Biancolillo, A., Roger, J. M., Marini, F., & Rutledge, D. N. (2020). New data preprocessing trends based on ensemble of multiple preprocessing techniques. *TrAC Trends in Analytical Chemistry*, 116045. <https://doi.org/10.1016/j.trac.2023.37.122>
- Pitchaimanickam, B., & Murugaboopathi, G. (2020). A hybrid firefly algorithm with particle swarm optimization for energy efficient optimal cluster head selection in wireless sensor networks. *Neural Computing and Applications*, 32(12), 7709-7723. <https://doi.org/10.1007/s00421-013-1738-9>
- Prasad, K. S., Reddy, N. C. S., & Puneeth, B. N. (2020). A Framework for Diagnosing Kidney Disease in Diabetes Patients Using Classification Algorithms. *SN Computer Science*, 1(2), 1-6. <https://doi.org/10.1007/s43226-020-00312-5>
- Shankar, K., Lakshmanaprabu, S. K., Gupta, D., Maseleno, A., & De Albuquerque, V. H. C. (2020). Optimal feature-based multi-kernel SVM approach for thyroid disease classification. *The journal of supercomputing*, 76(2), 1128-1143. <https://doi.org/10.1007/s00428-022-03656-6>
- Sheridan, K., Puranik, T. G., Mangortey, E., Pinon-Fischer, O. J., Kirby, M., & Mavris, D. N. (2020). An application of dbscan clustering for flight anomaly detection during the approach phase. In *AIAA Scitech 2020 Forum* (p. 1851). <https://doi.org/10.2514/6.2020-1499>
- Tang, S., Yuan, S., & Zhu, Y. (2020). Data preprocessing techniques in convolutional neural network based on fault diagnosis towards rotating machinery. *IEEE Access*, 8, 149487-149496. <https://doi.org/10.1109/ACCESS.2020.297982>
- Trachanatzi, D., Rigakis, M., Marinaki, M., & Marinakis, Y. (2020). A Firefly Algorithm for the Environmental Prize-Collecting Vehicle Routing Problem. *Swarm and Evolutionary Computation*, 100712. <https://doi.org/10.1016/j.swevo.2020.100712>
- Wang, Y., Gu, Y., & Shun, J. (2020, June). Theoretically-efficient and practical parallel DBSCAN. In *Proceedings of the 2020 ACM SIGMOD International Conference on Management of Data* (pp. 2555-2571). <https://doi.org/10.1145/3351053.3352711>
- Zhou, J., Nekouie, A., Arslan, C. A., Pham, B. T., & Hasani Panah, M. (2020). Novel approach for forecasting the blast-induced AOI using a hybrid fuzzy system and firefly algorithm. *Engineering with Computers*, 36(2), 703-712. <https://doi.org/10.1007/s00367-019-01277-0>