



An Intelligent System Based on Hybrid Deep Learning Techniques for Accurate Diagnosis of Cardiovascular Disease

Nadia Ghasemabadi¹ / Hossein Sadr^{2,3*} / Seyyed Ahmad Edalatpanah¹ / Zeinab Khodavardian⁴

¹ Department of Computer Engineering, Ayandegan Institute of Higher Education, Tonkabon, Iran.

² Neuroscience Research Center, Trauma Institute, Guilan university of Medical Sciences, Rasht, Iran

³ Department of Artificial Intelligence in Medicine, Faculty of Advanced Technologies, Iran University of Medical Sciences, Tehran, Iran

⁴ Department of Computer Engineering, Faculty of Electrical and Computer Engineering, Islamic Azad University, Science and Research Branch, Tehran, Iran.

ARTICLE INFO

DOI: 10.22041/ijbme.2025.2049757.1946

Received: 3/1/2025

Revised: 31/3/2025

Accepted: 9/4/2025

KEYWORDS

Data Mining Techniques
Deep Learning
AdaBoost-Convolutional
Neural Networks
Heart Disease

ABSTRACT

Heart disease is one of the leading causes of death in the world. If the current trend continues, 23.6 million people will die from heart disease by 2030; therefore, its accurate prediction can help reduce the mortality rate. Previous models have mainly used traditional machine learning algorithms, which have limitations in accuracy and generalizability. In this study, a new hybrid model based on Adabost and Convolutional Neural Network (CNN) is presented, which makes significant improvements in heart disease prediction by utilizing the power of deep learning and reinforcement algorithms. The dataset used includes data from Cleveland heart patients with 303 samples and 14 main features. Due to the imbalance of the data, the data of the two classes were first balanced using the random oversampling technique, so that each class included 242 samples. After balancing, the dataset was divided into two training and testing parts with a ratio of 80 to 20. The proposed model was compared with five popular algorithms including support vector machine, decision tree, random forest, logistic regression and naive Bayes. The results showed that our hybrid model outperformed the other methods with an accuracy of 87%. This study demonstrates that the combination of CNN adabus, along with data balancing, can be used as an efficient method for predicting heart disease.



ارائه یک سیستم هوشمند مبتنی بر ترکیب تکنیک‌های یادگیری عمیق برای تشخیص دقیق بیماری قلبی عروقی

نادیا قاسم آبادی^۱، حسین صدر^{۲*}، سید احمد عدالت پناه^۱، زینب خداوردیان^۴

^۱-گروه مهندسی کامپیوتر، موسسه آموزش عالی آیندگان، تنکابن، ایران.

^۲-مرکز تحقیقات علوم اعصاب، پژوهشکده تروما، دانشگاه علوم پزشکی گیلان، ایران.

^۳-گروه هوش مصنوعی در پزشکی، دانشکده فناوری های نوین، دانشگاه علوم پزشکی ایران، تهران، ایران.

^۴-گروه مهندسی کامپیوتر، دانشکده برق و کامپیوتر، دانشگاه آزاد اسلامی، واحد علوم و تحقیقات، تهران، ایران.

مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/ijbme.2025.2049757.1946

پذیرش: ۱۴۰۴/۱/۲۰

بازنگری: ۱۴۰۴/۱/۱۱

ثبت در سامانه: ۱۴۰۳/۱۰/۱۴

چکیده

واژه‌های کلیدی

بیماری قلبی یکی از مهم‌ترین علل مرگ‌ومیر در جهان است اگر روند فعلی ادامه یابد، ۲۳٫۶ میلیون نفر در سال ۲۰۳۰ بر اثر بیماری قلبی خواهند مرد؛ پس پیش‌بینی دقیق آن می‌تواند به کاهش نرخ مرگ‌ومیر کمک کند. مدل‌های پیشین عمدتاً از الگوریتم‌های سنتی یادگیری ماشین استفاده کرده‌اند که محدودیت‌هایی در دقت و تعمیم‌پذیری دارند. در این پژوهش، یک مدل ترکیبی جدید بر پایه آدابوست و شبکه عصبی پیچشی (CNN) ارائه شده است که با بهره‌گیری از قدرت یادگیری عمیق و الگوریتم‌های تقویتی، بهبود قابل توجهی در پیش‌بینی بیماری قلبی ایجاد می‌کند. مجموعه داده مورد استفاده شامل داده‌های بیماران قلبی کلیولند با ۳۰۳ نمونه و ۱۴ ویژگی اصلی است. به دلیل نامتوازن بودن داده‌ها، ابتدا با استفاده از تکنیک بیش نمونه‌گیری تصادفی داده‌های دو کلاس متوازن شدند، به طوری که هر کلاس شامل ۲۴۲ نمونه شد. پس از متوازن‌سازی، مجموعه داده به دو بخش آموزش و تست با نسبت ۸۰ به ۲۰ تقسیم شد. مدل پیشنهادی با پنج الگوریتم پرتکرار شامل ماشین بردار پشتیبان، درخت تصمیم، جنگل تصادفی، رگرسیون لجستیک و بیز ساده مقایسه شد. نتایج نشان داد که مدل ترکیبی ما با دقت ۸۷ درصد عملکرد بهتری نسبت به روش‌های دیگر دارد. این پژوهش نشان می‌دهد که ترکیب آدابوست CNN، همراه با متوازن‌سازی داده‌ها، می‌تواند به عنوان یک روش کارآمد برای پیش‌بینی بیماری قلبی مورد استفاده قرار گیرد.

تکنیک‌های داده‌کاوی
یادگیری عمیق
آدابوست-شبکه عصبی پیچشی
بیماری قلبی

۱- مقدمه

بیماری‌های قلبی مهم‌ترین علت بین‌المللی مرگ‌ومیر انسان‌ها هستند. بر اساس گزارشی که در سال ۲۰۱۹ توسط سازمان بهداشت جهانی انجام شد، تقریباً ۱۸ میلیون نفر در آن سال به دلیل بیماری‌های قلبی عروقی جان خود را از دست دادند که ۳۲ درصد از کل مرگ‌ومیرها را شامل می‌شود. تشخیص زودهنگام و صحیح این بیماری‌ها حتی برای پزشکان نیز دشوار است. در مجموع ۲۵ درصد از مردم به‌طور ناگهانی بدون هیچ‌گونه علایم قبلی بیماری قلبی می‌میرند [۱].

افزایش سطح فعالیت بدنی بدون در نظر گرفتن شرایط جسمی افراد ممکن است موجب تشدید بیماری یا حتی مرگ آن‌ها گردد که این خود یکی از چالش‌های قابل‌ملاحظه برای بیمارانی است که از وضعیت سلامتی خود مطلع نیستند [۲، ۳]. فعالیت‌های بدنی که یک فرد سالم و یک فرد مبتلا یا مشکوک به بیماری برای بهبود سبک زندگی و بازگشت سلامتی انجام می‌دهد نیز کاملاً متفاوت هستند از این‌رو تمرینات مناسب این افراد با توجه به وضعیت سلامتی آن‌ها شخصی‌سازی می‌شود؛ بنابراین یکی از چالش‌های تخصیص فعالیت بدنی مناسب به افراد بررسی وضعیت سلامتی این افراد است که بیماری قلبی از مهم‌ترین عوامل تاثیر گذار بر نوع فعالیت بدنی می‌باشد [۴، ۵]. انگیزه این پژوهش، ۱. تسریع فرایند تشخیص بیماری قلبی، ۲. ترکیب مدل پیشنهادی با یک توصیه‌کننده ورزشی به‌عنوان قدمی کوچک برای کمک به بیماران قلبی.

در صنعت مراقبت‌های بهداشتی، سیستم‌های هوشمند نقش مهمی در حفظ و ارتقای سلامت افراد ایفا می‌کنند. با توجه به رشد سریع حجم داده‌ها، مدیریت مؤثر و بهینه این اطلاعات امری ضروری است. گاهی اوقات، استخراج دستی اطلاعات مفید از داده‌های خام به دلیل ناسازگاری، عدم قطعیت، عدم دقت و شباهت، برای انسان‌ها بسیار دشوار می‌شود [۶، ۷]. به همین منظور از تکنیک‌های یادگیری عمیق برای تشخیص بیماری افراد می‌توان بهره برد. یادگیری عمیق یکی از آن پیشرفت‌های قابل‌توجه است که هوش مصنوعی را حتی هوشمندتر کرده است [۸]. یادگیری عمیق شاخه‌ای از یادگیری ماشین است که در سال ۲۰۰۶ نام‌گذاری شد [۹]. این روش پردازش داده با الهام از ساختار شبکه‌های عصبی مغز انسان شکل گرفته است و از تکنیک چندلایه برای یادگیری استفاده می‌کند [۱۰]. کار لایه‌ها را می‌توان به‌عنوان لایه‌ای در نظر گرفت که ورودی وزنی

را دریافت می‌کند، آن را به توابع عمدتاً غیرخطی تبدیل می‌کند و سپس خروجی را به لایه بعدی می‌فرستد. در یادگیری عمیق یک نمایش انتزاعی و فشرده از داده‌های خام در چندین لایه در شبکه تولید می‌شود. سپس، از این نمایش فشرده‌شده داده‌های ورودی برای تولید خروجی استفاده می‌شود. در طی فرآیند آموزش شبکه، این مرحله توسط شبکه عصبی بهینه می‌شود تا بهترین نمایش انتزاعی ممکن از داده‌های ورودی را به دست آورد. این بدان معناست که مدل‌های یادگیری عمیق برای انجام و بهینه‌سازی فرآیند استخراج ویژگی، به تلاش دستی بسیار کمی نیاز دارند [۱۱].

شبکه‌های عصبی با استفاده از داده‌های مختلف سعی بر یادگیری روندها و نتیجه‌گیری از این داده‌ها می‌کنند. شبکه‌های عمیق این فرایند را به‌وسیله ۲ مرحله انجام می‌دهند: ۱. انتشار جلوگرد^۱، ۲. انتشار عقب‌گرد^۲ [۱۲، ۱۳].

داده‌ها طی دو مرحله انتشار به جلوگرد و عقب‌گرد به شبکه عصبی وارد می‌شوند (فید شدن) و شبکه عصبی اطلاعات لازم را می‌آموزد. به هر بار انجام فرایند جلوگرد و عقب‌گرد یک دوره^۳ گفته می‌شود. به بیان دیگر اگر همه داده‌ها را یک‌بار وارد شبکه عصبی شود و در طی دو مرحله جلوگرد و عقب‌گرد، شبکه عصبی مواردی را از داده‌ها می‌آموزد. شبکه عصبی پیچشی^۴ نوعی شبکه عصبی است که شامل یک‌لایه ورودی، یک‌لایه خروجی و چندلایه پنهان است که معمولاً لایه‌های پیچشی، لایه‌های ادغام، لایه‌های کاملاً متصل یا لایه‌های نرمال‌سازی در آن قرار دارند. در شبکه عصبی پیچشی ایده این است که تعداد لایه‌ها را زیاد کرده و در عوض تعداد نورون‌ها کاهش یابد [۱۴، ۱۵]. مزیت این عمل یادگیری پیچیده‌تر و ظرایف ویژگی‌های کشف‌شده است. اگر لایه‌های پنهان در شبکه افزایش یابد، دقت روی داده‌های آموزش بالا می‌رود، اما به دلیل پدیده‌ی بیش‌برازش، دقت روی داده‌های آزمایشی کاهش می‌یابد. با بکارگیری تکنیک‌های یادگیری گروهی می‌توان به افزایش دقت طبقه‌بندی‌های ضعیف کمک کرد. الگوریتم پیشنهادی روش آدابوست رگرسیون^۵ است که بر شبکه عصبی پیچشی به‌عنوان مدل ضعیف‌تر اعمال شده است [۱۶]. در بخش دو به پیشینه پژوهش و بخش سوم به بررسی روش پیشنهادی و در بخش چهارم آزمایش‌ها و در آخر در بخش پنجم به بررسی نتایج آزمایش‌ها پرداخته می‌شود.

⁴ Convolutional Neural Network (CNN)

⁵ AdaBoost regressor

¹ Forward propagation

² Backward Propagation

³ Epoch

۲- کارهای پیشین

تحقیقات در مورد علل مرگ ناشی از بیماری قلبی نشان داده است که این بیماری اولین علت مرگ است. مطالعه بر روی بیماران قلبی به دو صورت هوشمند و غیرهوشمند تقسیم می‌شود. روش‌های غیرهوشمند همان روش‌های سنتی هستند و روش‌های هوشمند از دیدگاه داده‌کاوی به دودسته روش‌های فرا ابتکاری و روش‌های یادگیری ماشین تقسیم می‌شوند. الگوریتم‌های فرا ابتکاری گروهی از الگوریتم‌های تصادفی هستند که برای مسائل بهینه‌سازی استفاده می‌شود و اغلب به همراه الگوریتم‌های دیگر بکار می‌رود. گروهی دیگر از الگوریتم‌های هوشمند هستند که برای مسائل طبقه‌بندی و رگرسیون به کار می‌روند که از نوع الگوریتم‌های یادگیری ماشین هستند. الگوریتم‌های پرتکرار در پژوهش‌های مرتبط شامل ماشین بردار پشتیبان، درخت تصمیم، K-نزدیک‌ترین همسایه، بیز ساده و شبکه‌های عصبی بود، همانند پژوهش دی و همکاران که هدف از تحقیق، تجزیه و تحلیل الگوریتم‌های نظارت‌شده به سبب پیش‌بینی بیماری قلبی بود. این مجموعه هم شامل افرادی که بیماری قلبی داشتند می‌شوند و هم بیماری قلبی نداشتند. سه الگوریتم یادگیری تحت نظارت یعنی DT، NB و SVM در نظر گرفته شده بود. مجموعه داده‌های مورد استفاده در این مطالعه از کلینیک بنیاد کیولند مجموعه داده دارای ۱۱ ویژگی و ۳۰۳ ردیف است. هر ردیف مربوط به یک بیمار خاص است و هر ویژگی مربوط به مشاهدات یا نوع آزمایش‌ها برای بیماران است. در این مقاله، بیز ساده، ماشین بردار پشتیبان و درخت تصمیم در مجموعه داده‌ها اعمال می‌شود [۱۷]. الگوریتم شبکه عصبی ابزاری برای تعیین زود هنگام خطر بیماری قلبی با استفاده از داده‌های ساختاریافته است؛ که در اغلب پژوهش‌ها از داده‌های ساختاریافته UCI استفاده شده. پژوهش‌های زیادی برای مقایسه مدل‌های شبکه عصبی و سایر مدل‌های یادگیری ماشین انجام شد به‌عنوان مثال، لانگ و همکاران [۱۸]. الگوریتم پیشنهادی با بیز ساده ماشین بردار پشتیبان و شبکه عصبی مصنوعی نیز مقایسه شد. مجموعه داده‌ها از مخزن UCI گرفته شده بود که شامل ۲۷۰ رکورد و ۱۳ ویژگی است و در محیط متلب اجرا شد که الگوریتم شبکه عصبی مصنوعی از لحاظ دقت، همگرایی، سرعت و زمان پردازش، برتری داشت. در پژوهش مظاهری و همکاران [۱۹] دو الگوریتم شبکه عصبی مصنوعی و چهار درخت تصمیم (C0, Tree R&C, CHAID و QUEST) مورد بررسی قرار گرفت این پژوهش بر روی مجموعه داده بیمارستان خاتم الانبیا (ع) و علی بن ابی‌طالب (ع) انجام شد. تاثیرگذارترین پارامترها

در انتخاب روش درمان بیماری قلبی کلسترول، سیگاری بودن، قند خون، فشارخون و سن شناخته شده‌اند. پارامتر جنسیت اهمیت کمتری نسبت به سایر پارامترها دارد، یافته‌های این پژوهش نشان داد که درخت R&C نتیجه بهتری نسبت به شبکه‌های عصبی مصنوعی داشت. در پژوهش توماس و همکاران در سال ۲۰۱۶ انگیزه اصلی ارائه بینش در مورد تشخیص میزان خطر بیماری قلبی با استفاده از تکنیک‌های داده‌کاوی است. تکنیک‌های مختلف داده‌کاوی مانند، الگوریتم بیز ساده، K-نزدیک‌ترین همسایه، درخت تصمیم، شبکه عصبی برای پیش‌بینی خطر بیماری قلبی مورد استفاده قرار داد؛ که از طریق اضافه کردن ویژگی‌های اضافی مانند سیگار کشیدن و سابقه بیماری قلب دقت پیش‌بینی افزایش می‌یابد. با استفاده از ویژگی‌های اساسی مانند فشارخون، کلسترول، نرخ پالس، سن و جنس، سطح دقت پیش‌بینی ۴۰٪ بود و زمانی که دو ویژگی اضافی مانند سیگار کشیدن و بیماری‌های قلبی اضافه شد، سطح دقت پیش‌بینی افزایش یافت [۲۰]. الیاس توگی [۲۱] با مجموعه داده‌ای دارای ۱۳ ویژگی، یک متغیر هدف و ۳۰۳ مورد است که در آن ۱۳۹ مورد از بیماری‌های قلبی عروقی و ۱۶۴ فرد سالم هستند، از شش تکنیک یادگیری ماشین، همسایه، شبکه عصبی مصنوعی، بیز ساده و جنگل تصادفی و با سه معیار عملکرد برای مقایسه دقت، حساسیت و صحت برای هر تکنیک به این نتیجه رسید که مدل شبکه عصبی مصنوعی بهترین عملکرد را دارد.

تکنیک‌های یادگیری جمعی (گروهی) برای ترکیب دو یا چند طبقه‌بند ساده بکار می‌روند، این تکنیک برای بهبود عملکرد روند پیش‌بینی مدل در پژوهش‌های پیشین پرکاربرد بوده مثلاً اوستین و همکاران از روش‌های داده‌کاوی به منظور پیش‌بینی بیماری قلبی استفاده نمودند. آن‌ها از چندین روش درخت تصمیم کارت، درخت تصمیم، درخت تصادفی، درخت تصمیم بوستینگ، رگرسیون لجستیک به منظور رده‌بندی بیماران استفاده کردند. مشخص شد که روش رگرسیون لجستیک از سایر روش‌ها در رده‌بندی بیماران موفق‌تر بوده است با این حال روش‌های رده‌بندی جمعی که بر پایه درخت تصمیم نیز تشکیل شده بودند کارایی مناسبی داشتند [۲۲]. همین‌طور در پژوهش میاو و همکاران تکنیک پیشرفته ماشین‌های یادگیری با استفاده از الگوریتم سازگار بوستینگ برای تشخیص بیماری قلبی ارائه شده است. در این کار از ۴ مجموعه داده‌ی، سینجر

یک مرحله پیش‌پردازش داده‌ها با انتخاب ویژگی‌ها پیاده‌سازی شد.

آزمایش‌ها با مدل‌های شبکه عصبی یک‌طرفه و دوطرفه انجام شدن و نتایج نشان داد که یادگیر گروهی بر پایه مدل BiLSTM و شبکه عصبی پیچشی بهترین عملکرد طبقه‌بندی را با دقت و امتیاز F1 بین ۹۱ تا ۹۶ درصد برای انواع مختلف بیماری قلبی دارد. آن‌ها دریافتند که چارچوب یادگیری گروهی مبتنی بر مدل‌های عمیق می‌تواند بر مشکل طبقه‌بندی مجموعه داده‌های نامتعادل بیماری قلبی غلبه کند [۲۴].

در جدول ۱ به اختصار مدل‌های بکار رفته در پژوهش‌های پیشین را می‌توان مشاهده کرد.

کلیندل، موسسه قلب‌شناسی مجارستان^۱، مرکز پزشکی لانگ بیچ^۲ و بیمارستان دانشگاه سوئیس^۳ برای تشخیص بیمارهای قلبی استفاده شده است که شامل ۳۰۳ نمونه بالینی، ۲۹۴ نمونه بالینی، ۲۰۰ نمونه بالینی و ۱۲۳ نمونه بالینی در هر مجموعه داده است. در این مقاله تکنیک‌های ماشین‌های یادگیری دقت بالایی را ارائه داده است [۲۳].

در سال ۲۰۲۰ در مکزیک اسما بکوش و همکاران بر روی داده‌های بیمارستان مدیکا نورث^۴ که شامل ۸۰۰ رکورد و ۱۴۱ شاخص مانند سن، وزن، گلوکز، میزان فشارخون و علائم بالینی است، یک چارچوب یادگیری گروهی از مدل‌های مختلف شبکه عصبی و روشی برای جمع‌آوری نمونه‌برداری تصادفی پیشنهاد کردند. برای بهبود عملکرد الگوریتم‌های طبقه‌بندی،

جدول (۱) - ارزیابی مدل‌های موجود.

نام نویسنده و سال چاپ	رگرسیون لجستیک	درخت تصمیم	ماشین بردار پشتیبان	بیز ساده	جنگل تصادفی	شبکه عصبی	مجموعه داده	دقت	تکنیک برتر
دی و همکاران (۲۰۱۶)	-	✓	✓	✓	-	-	مجموعه داده UCI	۶۵	ماشین بردار پشتیبان
مظاهری و همکاران (۲۰۱۷)	-	✓	-	-	-	✓	بیمارستان خاتم الانبیا (ع) و علی بن ابی‌طالب (ع)	۸۱/۴۹	شبکه عصبی مصنوعی (فاخته)
بین و کمات (۲۰۱۸)	-	✓	✓	✓	-	-	مجموعه داده UCI	۸۹	ماشین بردار پشتیبان
اسما بکوش و همکاران (۲۰۲۰)	-	-	✓	-	-	✓	مجموعه داده بیمارستان medica norte	۹۶	شبکه عصبی پیچشی
الباس توگی و همکاران (۲۰۲۰)	✓	-	✓	-	✓	✓	مجموعه داده UCI	۸۶/۸۵	شبکه عصبی مصنوعی
کاتاریا و همکاران (۲۰۲۱)	✓	✓	✓	✓	✓	✓	مجموعه داده UCI	۹۵/۶۰	جنگل تصادفی

ورودی در سیستم وارد مرحله متوازن‌سازی و نرمال‌سازی می‌شود.

۱-۳- متوازن‌سازی داده

هنگامی که در یک فرایند داده‌کاوی مبتنی بر یادگیری با نظارت از یک مجموعه داده‌کاوی کلاس‌های با ماهیت فوق‌العاده نامتوازن استفاده می‌شود سوگیری بسیار از الگوریتم‌های داده‌کاوی نیز به سمت پیش‌بینی کلاس اکثریت^۵ متمایل می‌شود، این در حالی است که در چنین رویکردهایی عموماً تشخیص صحیح برچسب کلاس اقلیت^۶ حائز اهمیت است [۲۵].

۳- روش پیشنهادی

روش پیشنهادی مطابق شکل ۱ شامل یک فاز پیش‌پردازش است که نتیجه نهایی آن وارد یک چرخه آدابوست و شبکه عصبی پیچشی می‌شود و در نهایت پس از اعمال الگوریتم بر روی مجموعه داده به فاز تصمیم‌گیری هدایت می‌شود. تمام این مراحل در ادامه به صورت جداگانه تشریح شده‌اند.

۱-۳- پیش‌پردازش

در این پژوهش به منظور آماده‌سازی داده‌ها برای طبقه‌بندی توسط مدل پیشنهادی عملیات پیش‌پردازش بر روی مجموعه داده به دست آمده انجام خواهد شد؛ بنابراین مجموعه داده

⁴ Medica Norte

⁵ Majority class

⁶ Minority class

¹ Hungarian Institute of Cardiology (HIC)

² LBMC

³ Swiss University Hospital (SUH)

مطابق شکل ۲ افزایش نمونه‌ها باعث خواهد شد نمونه‌های زیادی در کلاس اقلیت جای گیرد و تعداد داده‌های هر دو کلاس برابر شود.

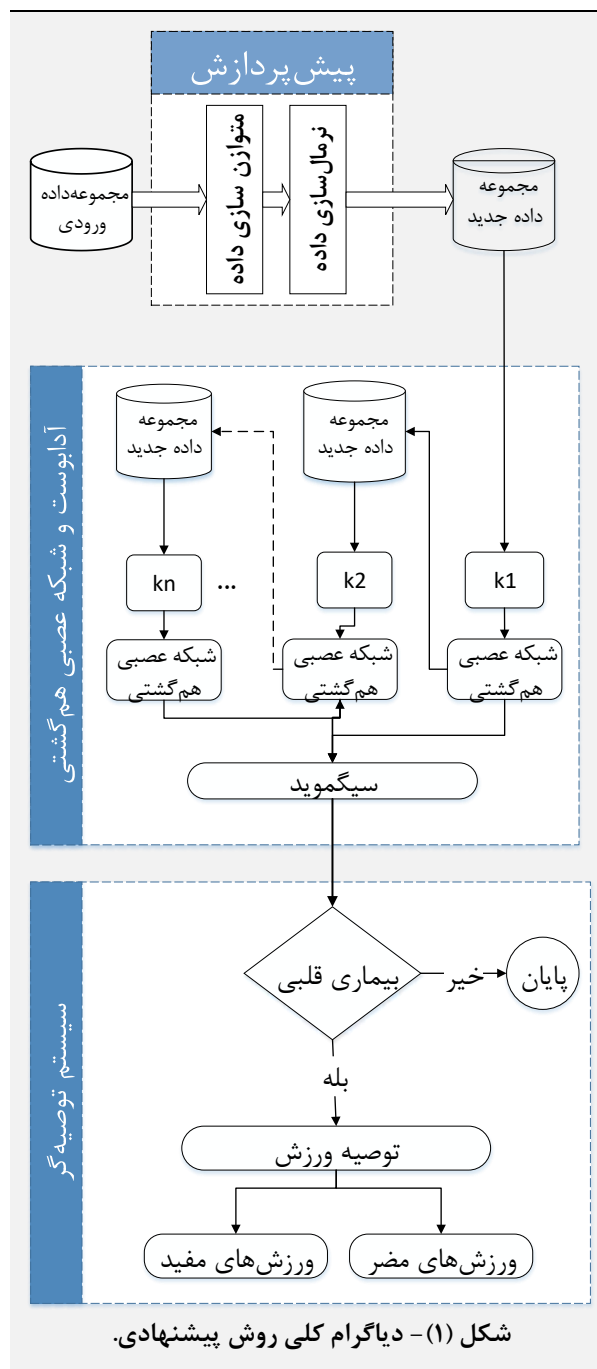
۲-۱-۳- نرمال‌سازی

در آموزش گروهی از الگوریتم‌های یادگیری ماشین، یکی از نکات مهمی که باید به آن توجه داشت، نرمال‌سازی داده‌ها قبل از استفاده از آن‌ها در مدل است. این پروسه به‌ویژه زمانی که دامنه تغییرات در ورودی‌ها بالا باشد، کمک بسیاری به بهبود عملکرد مدل می‌کند. لازم به ذکر است که پارامترهای نرمال‌سازی باید فقط از داده‌های آموزش استخراج شده و سپس همان پارامترها به داده‌های تست اعمال شوند. این نکته بسیار حائز اهمیت است تا از نشت اطلاعات از داده‌های تست به داده‌های آموزش جلوگیری کرده و عملکرد مدل به‌طور صحیح ارزیابی گردد. در این پژوهش نیز از فرایند نرمال‌سازی برای افزایش سرعت و دقت مدل استفاده شده است. یکی از روش‌های نرمال‌سازی که در این مقاله استفاده شده، روش نرمال‌سازی Z است. این روش داده‌های ورودی را به یک محدوده ثابت جدید (بین -۱ تا ۱) تغییر می‌دهد [۲۲].

۳-۱-۳- مدل پیشنهادی

چندین طبقه‌بندی کننده ضعیف با تکنیک‌های آداپوست ترکیب می‌شوند تا یک طبقه‌بندی قوی ایجاد کنند [۲۷]. الگوریتم پیشنهادی در این پژوهش بکارگیری شبکه عصبی پیچشی به‌عنوان مدل ضعیف‌تر در چرخه آداپوست است. هر طبقه‌بندی کننده بر اساس خطاهای طبقه‌بندی کننده قبلی آموزش داده شده است و وزنی به هر نمونه تمرینی اختصاص می‌یابد تا نشان دهد که تا چه حد نمونه به‌درستی با طبقه‌بندی کننده ضعیف آموزش ندیده است. اگر نمونه به‌طور صحیح توسط طبقه‌بندی ضعیف قبلی آموزش داده شود، وزن نمونه به‌صورت تصاعدی کاهش می‌یابد.

هر طبقه‌بندی کننده ضعیف جدید با وزن‌های بیشتری برای آن دسته از نمونه‌هایی که بر اساس نتایج طبقه‌بندی ضعیف قبلی که به‌درستی آموزش داده نشده‌اند، آموزش داده می‌شود. الگوریتم پیشنهادی در این پژوهش بکارگیری شبکه عصبی پیچشی به‌عنوان مدل ضعیف‌تر در چرخه آداپوست است مطابق شکل ۲ در چرخه آداپوست نخست وزن دهی به نمونه‌ها به صورت تصادفی است اگر هر نمونه n در نظر بگیریم وزن هر



شکل (۱) - دیاگرام کلی روش پیشنهادی.

یکی از روش‌های حل مشکل فوق، استفاده از روش‌های متوازن‌سازی در سطح داده‌ها است که خود مبتنی بر روش‌های بیش نمونه‌گیری^۱ و کم نمونه‌گیری^۲ است [۲۶]. در این پژوهش از روش بیش نمونه‌گیری تصادفی استفاده شده به دلیل با ارزش بودن داده‌ها از کم نمونه‌گیری استفاده نشده و به خاطر اینکه داده‌ها مربوط به اشخاص واقعی هستند و تولید یک نمونه جدید عملاً ممکن نیست از بیش نمونه‌گیری تصادفی استفاده شده.

² Undersampling

¹ Oversampling

ویژگی^۱ به دست آمده از فیلتر از نظر عرض و ارتفاع هم اندازه فیلتر است [۲۸].

از سه لایه پیچشی که هر کدام دارای ۴ گره با سایز ۲×۲ است و مقادیر خروجی از لایه پیچشی باید از تابع فعالسازی غیرخطی Relu عبور کنند. در غیر این صورت شبکه قادر به یادگیری الگوهای غیرخطی موجود در داده‌ها نخواهد بود. استراتژی ادغام بیشینه پس از لایه پیچشی و باهدف کاهش اندازه نقشه‌های ویژگی به کار می‌رود و می‌تواند باعث انتخاب ویژگی‌های نامتغیر و با ارزش بیشتر شود. پیش از لایه حذف تصادفی از یک لایه مسطح ساز^۲ به کار برده شده که آرایه‌های دوبعدی نگاشت ویژگی را به یک بعد تبدیل می‌کند.

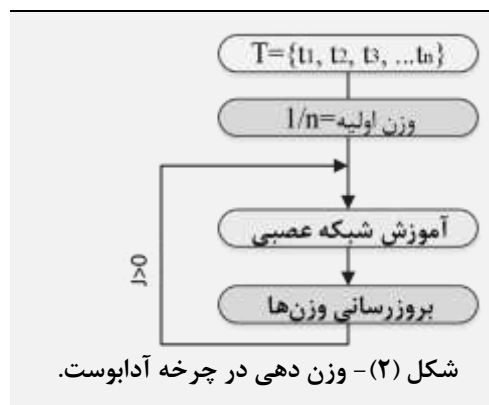


تابع غیرخطی مشتق پذیر سیگموئید شکل خاصی از تابع لجستیک است و معمولاً با $\sigma(x)$ یا $\text{sig}(x)$ نشان داده می‌شود. این تابع یکنواخت افزایشی نوعی توازن بین رفتار خطی و غیرخطی ایجاد می‌کند و به دلیل مشتق پذیر بودن باعث بهبود

نمونه $\frac{1}{n}$ است. بعد از آموزش مدل اول، با کل داده های تست، تست می شود تا خطای مدل بدست بیاید. رابطه (۱) نمایانگر یک تابع خطا یا هزینه است که در هر تکرار الگوریتم محاسبه می‌شود. در این رابطه، J نشان دهنده مقدار کلی خطا یا تابع هزینه در هر مرحله از الگوریتم است که هدف الگوریتم کاهش آن در طول تکرارها است. n تعداد کل نمونه‌های آموزشی موجود در مجموعه داده است و W_J یا همان وزن نمونه آموزشی J در تکرار فعلی الگوریتم است که در هر مرحله آپدیت شده و نمونه‌های دشوارتر را هدف قرار می‌دهد.

$$J = \sum_J^n W_J + J_1 \quad (1)$$

بر اساس میزان خطا به مدل وزن اختصاص می‌یابد تا در پروسه تست اهمیت رای آن را مشخص کند. سپس وزن نمونه‌هایی که درست طبقه بندی شده اند کمتر شده و وزن نمونه‌هایی که اشتباه دسته بندی شده بیشتر می‌شود. با اینکار مدل بعدی متوجه می‌شود که کجا باید تمرکز کند و سعی کند چه نمونه‌هایی را درست دسته بندی کند. این پروسه به ازای تمام k مدل تکرار می‌شود. این حلقه زمانی متوقف می‌شود که شرط توقف برقرار باشد؛ یعنی $J \geq 0.5$ یا $J = 0$.



تمام مدل‌ها در این روش پیشنهادی از نوع شبکه عصبی پیچشی است. این مدل شامل یک لایه ورودی، یک لایه خروجی و چند لایه پنهان است که معمولاً لایه‌های پیچشی، لایه‌های ادغام، لایه‌های کاملاً متصل یا لایه‌های نرمال سازی در آن قرار دارند. وزن‌ها در هر لایه پیچشی، توسط فیلترهای مشخص می‌شوند. ممکن است چندین فیلتر در هر لایه پیچشی وجود داشته باشد. هر فیلتر ویژگی‌های متفاوتی را استخراج می‌کند، نگاشت

² Flatten

¹ Feature map

جهت ورزش‌هایی که در سیستم توصیه‌گر به کاربر بیمار توصیه می‌شود در قالب جدول ۲ تدوین شده‌است.

۴- آزمایش‌ها

در این بخش از تحقیق به بررسی و تجزیه و تحلیل داده‌های به دست آمده پرداخته خواهد شد. داده‌های دریافتی با استفاده از آزمون‌ها و آزمایش‌ها ذکر شده در فصل چهارم آنالیز می‌شوند. در این فصل به سه بخش اصلی پرداخته خواهد شد در بخش اول روش تجزیه و تحلیل اطلاعات است که شامل توصیف مجموعه داده به کاررفته و شناخت معیار ارزیابی همچنین سخت‌افزار و نرم‌افزارهای مورد استفاده برای پیاده‌سازی می‌شود. در بخش دوم به توصیف آزمایش‌ها، مرحله پیش‌پردازش، ساخت مدل پیشنهادی و آموزش مدل پرداخته می‌شود. در آخر به بررسی نتایج پیاده‌سازی پرداخته خواهد شد.

۴-۱- مجموعه داده

در این پژوهش داده‌های پزشکی از مجموعه داده UCI دریافت شده‌است [۳۳]. این سایت دارای مجموعه داده‌های پزشکی هست که مجموعه داده قلبی آن شامل ۳۰۳ نمونه و ۷۶ ویژگی است که تمام آزمایش‌های انجام شده روی ۱۴ ویژگی اصلی از آن اشاره دارد و فیلد هدف وضعیت نهایی فرد را که بیمار و یا نرمال خواهد بود، نشان می‌دهد. داده‌های بکار رفته در این پژوهش مربوط به ۳۰۳ مراجعه‌کننده بدون سابقه سکته قلبی هستند که در بیمارستان کلیولند آمریکا تحت آنژیوگرافی کرنری قرار گرفتند و ویژگی‌های بالینی و دموگرافی آن‌ها ثبت شده‌است.

۴-۲- معیار ارزیابی

بعد از جمع‌آوری اطلاعات و استخراج ویژگی با استفاده از معیار دقت که در رابطه (۳) اشاره شده به بررسی روش پیشنهادی پرداخته شده‌است. پس از ساخت مدل از روش ماتریس درهم ریختگی داده‌های آزمون با مدل بررسی داده‌های خروجی مدل با داده‌های واقعی مقایسه شده‌است [۳۴].

جدول (۴) - ماتریس درهم ریختگی.

		مثبت	منفی
$\begin{matrix} \text{مثبت} \\ \text{خطای نوع ۱} \end{matrix}$	$\begin{matrix} \text{مثبت} \\ \text{درست} \end{matrix}$	(TP) درست	(FN) نادرست
	$\begin{matrix} \text{منفی} \\ \text{نادرست} \end{matrix}$	(FP) نادرست	(TN) درست
		مثبت	منفی

کیفیت آموزش شبکه عصبی می‌شود. می‌توان این تابع را با زبان ریاضی به صورت رابطه (۲) تعریف کرد:

$$\sigma_{(x)} = \frac{1}{1+e^{-x}} \quad (2)$$

تابع سیگموئید در این پژوهش به سبب این که کلاس مورد نظر دارای دو مقدار (۰ و ۱) است استفاده شد. در این پژوهش یک سیستم توصیه کننده فعالیت ورزشی به مدل پیشنهادی به عنوان نمونه ای از کاربردهای مدل اضافه شده است که پس از پیش‌بینی نمونه‌های مجموعه داده و اختصاص کلاس بیمار یا سالم به آن، به یک سیستم توصیه کننده ورزشی هدایت می‌شود. سیستم توصیه‌گر انتخاب آیت‌م مناسب افراد را تسریع کرده است [۲۹]. این سیستم زیرمجموعه‌ای از سامانه پشتیبان تصمیم می‌توان دانست و آن‌ها را سیستم‌های اطلاعاتی تعریف کرد که توانایی تحلیل رفتارهای گذشته و ارائه توصیه‌هایی برای مسائل جاری را دارا هستند [۳۰]. به‌طور رسمی می‌توانیم سیستم توصیه کننده را با S به عنوان مجموعه‌ای از همه مواردی که ممکن است به کاربران توصیه شود، U به عنوان مجموعه‌ای از همه کاربرانی که سیستم برای آن‌ها توصیه می‌کند و F را به عنوان تابع مفیدی که می‌توان برای اندازه‌گیری سودمندی استفاده کرد، تعریف کرد. از یک آیت‌م خاص $s \in S$ به کاربر خاص $u \in U$ از نظر ریاضی می‌توان آن را به صورت $F: U \times S \rightarrow R$ نشان داد که در آن R کل مجموع توصیه شده را نشان می‌دهد. بیماران قلبی باید به خوبی ورزش‌هایی که برای آن‌ها ممنوع و مضر است را بشناسند تا آن‌ها را انجام ندهند و موجب نشوند وضعیت قلب‌شان وخیم‌تر شود [۳۱].

جدول (۲) - ورزش‌های مفید و مضر برای بیماران قلبی.

ورزش‌های مضر برای بیماران قلبی	ورزش‌های مفید برای بیماران قلبی
دویدن طولانی مدت و شدید (ماراتن)	پیاده‌روی آهسته
شنا سوئدی	دویدن آهسته
دراز نشست	شنا کردن
وزنه برداری	دیپ پارالل
ورزش‌های حرفه ای بدون تجربه (فوتبال، بسکتبال و ...)	طناب زدن آهسته
قایق‌رانی	اسکات
ورزش‌های رزمی (کاراته، بوکس و ...)	رقصیدن

ورزش‌هایی مانند وزنه برداری که به زور زدن نیاز دارند و موجب می‌شوند قلب متحمل فشار شود، اصلاً به بیماران قلبی و عروقی توصیه نمی‌شود و نباید آن‌ها را خیلی انجام داد [۳۲]. از این

می‌تواند خطای بین یک احتمال پیش‌بینی‌شده و برچسبی که کلاس واقعی را نشان می‌دهد اندازه‌گیری کند.

۳-۴- نیازهای سیستمی

در این بخش از پژوهش به پیش‌نیازهای سخت‌افزاری و نرم‌افزاری برای پیاده‌سازی مدل پیشنهادی پرداخته شده است. مشخصات سیستمی سخت‌افزار مورد استفاده شامل پردازنده با معماری Intel(R) با تعداد هسته Core i5 3337U با سرعت 1.80GHz است. سیستم مورد استفاده از نوع x64 با 4GB رم و سیستم عامل Windows 7 است. برای پیاده‌سازی مدل پیشنهادی در فضای گوگل کولب^۲ با زبان برنامه‌نویسی پایتون^۳ استفاده شده است؛ زیرا در این بستر به دلیل اینکه کتابخانه‌ها از پیش نصب شده‌اند، مبتنی بر وب است و چون در فضای ابری ذخیره‌سازی می‌شود، به سرعت و راحتی پیاده‌سازی کمک خواهد کرد. کتابخانه‌های مورد استفاده برای پیاده‌سازی مدل پیشنهادی به شرح زیر است:

پانداس: پانداس یک کتابخانه قدرتمند برای بارگذاری کردن، تحلیل، پیش‌پردازش و بصری سازی داده‌ها است. سای کیت لرن^۴: برای تغییر و پیش‌پردازش داده‌ها، پیاده‌سازی الگوریتم‌ها استفاده شده است. کتابخانه مت‌پلات^۵ و سیرن^۶: از این دو کتابخانه برای ترسیم نمودارها و مصورسازی نتایج استفاده شده است. پس از وارد کردن کتابخانه‌ها نوبت به وارد کردن داده‌های مورد استفاده می‌رسد. در بخش بعد داده‌های فراخوانی شده وارد مرحله پیش‌پردازش می‌شوند.

۴-۴- پیش‌پردازش داده‌ها

برای پیش‌پردازش داده‌ها معمولاً با کتابخانه پانداس پایتون کار می‌شود. این کتابخانه برای وارد کردن داده‌ها و مدیریت آن‌ها بسیار پرکاربرد است و چون مجموعه داده ما به فرمت CSV است، کتابخانه پانداس به راحتی می‌تواند با این فرمت داده کار کند.

نرمال‌سازی: برای اینکه اطلاعات تست تا حد ممکن واقعی نگه داشته شود از نرمال‌سازی استفاده می‌شود. نرمال‌سازی بین ۱- تا ۱ از طریق روش نمره Z طبق فرمول زیر انجام شده است.

جدول (۳) - ویژگی بکار رفته در مجموعه داده کیولند.

ردیف	ویژگی	مقدار	نوع داده
۱	age	-	صحیح
۲	sex	۰- زن ۱- مرد	صحیح
۳	cp	۰- ۱- ۲- آنژین غیرمعمول ۳- آنژین غیر آنژین ۴- بدون علامت	صحیح
۴	trestbps	-	صحیح
۵	chol	-	صحیح
۶	fbs	۰- نادرست ۱- درست	صحیح
۷	Restecg	۰- نرمال ۱- ناهنجاری موج ST- ۲- همپرتروفی ۳- بطن چپ	صحیح
۸	Thalach	-	صحیح
۹	Exang	۰- خیر ۱- بله	صحیح
۱۰	Oldpeak	-	شناور
۱۱	Slope	۰- شیب به بالا ۱- مسطح ۲- شیب به پایین	صحیح
۱۲	Ca	۰ ۱ ۲ ۳	صحیح
۱۳	Thal	۰- طبیعی ۱- نقص رفع شده ۲- نقص قابل برگشت ۳- نقص	صحیح
۱۴	Num	۰- باریک شدن کمتر از ۵۰٪ قطر (عادی) ۱- باریک شدن بیشتر از ۵۰٪ قطر (بیمار)	صحیح

(خطای نوع ۲)

در جدول ۴، TP و TN به ترتیب نمونه‌های مثبت و منفی هستند که مدل درست طبقه‌بندی کرده است. همچنین FP و FN به ترتیب نمونه‌های مثبت و منفی هستند که نادرست طبقه‌بندی شده‌اند.

$$(۳) \quad \text{دقت} = \frac{(TP+TN)}{(TP+FN+FP+TN)}$$

آموزش مدل‌های شبکه عصبی عمیق به منظور به حداقل رساندن تابع زیان فرمول‌بندی شده است. در این زمینه، آموزش یک شبکه عصبی عمیق به معنای جستجوی مجموعه‌ای از مقادیر پارامترهای شبکه است که در آن تابع زیان حداقل مقدار را دارد. در این پژوهش به دلیل پیش‌بینی خروجی در محدوده صفر تا یک از تابع ضرر آنتروپی متقاطع^۱ یا به طور مشخص‌تر آنتروپی متقاطع دودویی استفاده شده است. تابع ضرری که

⁴ Sklearn

⁵ Matplotlib

⁶ Seaborn

¹ Cross entropy loss function

² Google Collaboratory

³ Python



شکل (۵) - همبستگی بین ویژگی‌ها.

ابریارامترها: پس از پیش‌پردازش و نرمال‌سازی داده‌ها، مجموعه داده به دو دسته آموزش و تست تقسیم می‌شود. این تقسیم‌بندی با درصد ۸۰ به ۲۰ صورت گرفته است. مدل‌ها در کراس به عنوان دنباله‌ای از لایه‌ها تعریف شدند. یک مدل ترتیبی^۱ ایجاد شده است. لایه‌ها یکی یکی اضافه شده تا این که معماری موردنظر شکل بگیرد.

گام اول اطمینان از این است که لایه ورودی از تعداد ورودی‌های مناسب برخوردار باشد. این را می‌توان هنگام ایجاد اولین لایه با آرگومان این پوت-دیم^۲ و تنظیم آن روی ۱ برای ۱۳۷ متغیر ورودی، تعیین کرد. پی‌بردن به تعداد لایه‌ها و انواع مناسب آن بسیار دشوار است و غالباً بهترین ساختار شبکه از طریق آزمایش‌های آزمون و خطا به دست می‌آید. در این پژوهش، از یک ساختار شبکه کاملاً متصل با سه لایه استفاده شده است و سایر ابریارامترها در **جدول ۵** آورده شده‌اند. مقدار وزن‌ها به عنوان یک پارامتر به طور پیش‌فرض در هر تکرار به روزرسانی می‌شود، اما مقادیر ابریارامترها توسط کاربر تنظیم و از طریق آزمون و خطا محاسبه شده‌اند.

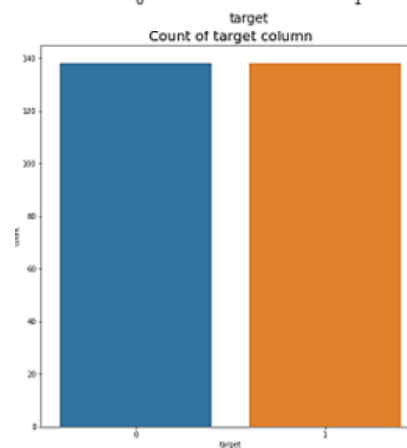

جدول (۵) - ابریارامترها.

مقدار	ابریارامتر
Relu	توابع فعال‌سازی
سیگموئید	تابع دسته‌بند
۳	تعداد فیلتر
۲×۲	اندازه کرنل
۱	اندازه پولینگ
۰/۳	نرخ حذف تصادفی
۵۰	تعداد دوره
آدام	بهینه‌سازی وزن‌ها
آنتروپی متقاطع	تابع خطا
۱۷	تکرار حلقه آدابوست

درمجموع ۱۳ ویژگی و ۱ متغیر هدف وجود دارد. همچنین، هیچ مقدار گم‌شده‌ای وجود ندارد، بنابراین نیازی به مراقبت از مقادیر تهی نیست.

$$x' = \frac{x - \text{میانگین}(x)}{\text{واریانس}(x)} \quad (۴)$$

متوازن‌سازی داده‌ها: در مجموعه داده به دست آمده، با توجه به ویژگی تارگت که شامل دو کلاس ۱ و ۰ است و به ترتیب دارای ۱۳۸ و ۱۶۵ نمونه بود، مشخص شد که داده‌ها نامتوازن بودند و نیاز به متوازن‌سازی داشتند. برای رفع این عدم توازن، از روش بیش نمونه‌گیری تصادفی استفاده شد که در نتیجه آن، تعداد نمونه‌های هر دو کلاس به ۲۴۲ رسید.




شکل (۴) - نمودار توزیع نمونه در هر کلاس قبل و بعد از متوازن‌سازی.

همبستگی ویژگی‌ها: در مرحله بعد همبستگی بین ویژگی‌ها مقایسه می‌شود و چند ویژگی که ضریب همبستگی آن بیشتر از ۰/۹ بود حذف خواهد شد. با توجه به شکل ۵ ضریب همبستگی بیشتر از ۰/۹ مشاهده نمی‌شود. به راحتی می‌توان فهمید که هیچ ویژگی واحدی وجود ندارد که همبستگی بسیار بالایی با مقدار هدف داشته باشد. همچنین برخی از ویژگی‌ها با مقدار هدف همبستگی منفی و برخی مثبت دارند.

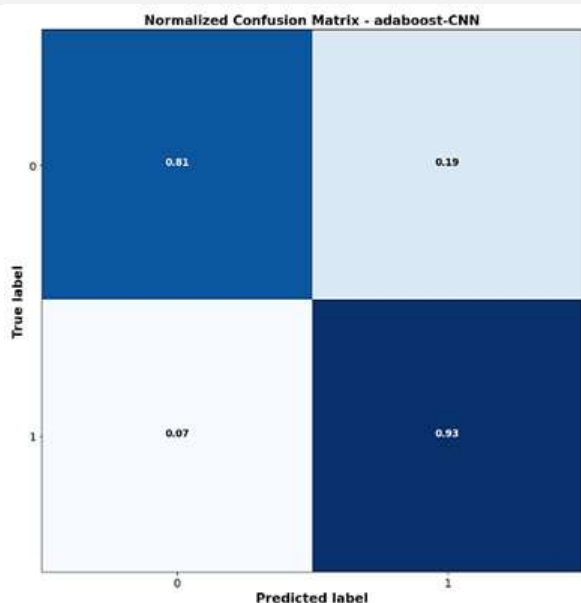
² input_dim

¹ Sequential



شکل (۷) - نمودار همگرایی مدل روی داده‌های آموزش بر اساس خطا.

اجرای مراحل آموزش مدل شبکه عصبی پیچشی بر روی داده‌های آموزشی در ۵۰ دور (اپوک) روی دور ۲۵ به همگرایی رسیده است و در چرخه آدابوست ۱۷ بار در میانگین ۳ دقیقه تکرار شده است. بیشترین میزان دقت در اپوک ۵۰ در دور ۱۳ آدابوست بود که به دقت ۸۹ درصد رسیده است. ماتریس درهم ریختگی برای کلاس هدف به شکل زیر نمایش داده شده است.




شکل (۸) - ماتریس درهم ریختگی.

در این پژوهش مجموعه داده با مدل‌های مختلف اجرا شده است. سپس به ساخت مدل پیشنهاد از ترکیب شبکه عصبی پیچشی و آدابوست پرداخته شده است. در جدول ۶ میزان دقت برحسب درصد برای مدل پیشنهادی و سایر مدل‌های پرتکرار بر روی مجموعه داده مورد بررسی مشاهده می‌شود.

آموزش مدل‌های شبکه عصبی عمیق به‌منظور به حداقل رساندن تابع زیان فرمول‌بندی شده است. در این زمینه، آموزش یک شبکه عصبی عمیق به معنای جستجوی مجموعه‌ای از مقادیر پارامترهای شبکه است که در آن تابع زیان حداقل مقدار را دارد. در این پژوهش به دلیل پیش‌بینی خروجی در محدوده صفر تا یک از تابع ضرر آنتروپی متقاطع^۱ یا به‌طور مشخص‌تر آنتروپی متقاطع دودویی استفاده شده است. تابع ضرری که می‌تواند خطای بین یک احتمال پیش‌بینی شده و برجسی که کلاس واقعی را نشان می‌دهد اندازه‌گیری کند.

۴-۵- نتایج پیاده‌سازی

در لایه ورودی یک ماتریس دوبعدی را دریافت می‌کند که شامل ۱۳ ویژگی است، خروجی این لایه هم یک ماتریس دوبعدی است. در لایه بعدی اولین لایه پیچشی یک‌بعدی قرار گرفته است که ورودی آن خروجی لایه قبل است یعنی همان ماتریس دوبعدی با ۱۳ ستون که ویژگی‌ها هستند. خروجی این لایه یک ماتریس دوبعدی است. در مرحله بعدی لایه ادغام بیشینه قرار گرفته است که خروجی لایه پیچشی اول را به‌عنوان ورودی دریافت می‌کند و خروجی حاصل از عملیات وارد لایه پیچشی دوم می‌شود و این فرایند طی دو مرحله تکرار می‌شود در مرحله ششم خروجی ادغام بیشینه لایه پیچشی سوم وارد فاز مسطح سازی و از یک ماتریس دوبعدی به یک لیست یک‌بعدی که به‌صورت بردار است ظاهر می‌شود این مقدار در انتها توسط لایه متراکم از ۱۷۶ نورون به یک نورون منفرد تبدیل می‌شود. نمودار ولیدیشن نشان‌دهنده تعمیم‌پذیری مدل است که در شکل ۶ آمده است.



شکل (۶) - نمودار همگرایی مدل روی داده‌های آموزش بر اساس دقت.

^۱ Cross entropy loss function

دقت مدل ۸۷ درصد (نشان می‌دهد که مدل در ۸۷ درصد موارد پیش‌بینی درستی انجام داده است.

صحت: صحت کلاس ۰ (۹۳/۰) بالاتر از صحت کلاس ۱ (۸۲/۰) است، به این معنا که مدل در پیش‌بینی کلاس ۰ کمتر دچار مثبت کاذب^۳ شده است.

حساسیت یا فراخوانی: حساسیت کلاس ۱ (۹۳/۰) بالاتر از حساسیت کلاس ۰ (۸۱/۰) است، یعنی مدل در شناسایی نمونه‌های کلاس ۱ عملکرد بهتری داشته و موارد منفی کاذب^۴ در کلاس ۱ کمتر بوده است.

معیار-F1: هر دو کلاس نزدیک به هم (حدود ۸۷/۰) است، که نشان می‌دهد مدل تعادل نسبی بین حساسیت و صحت را حفظ کرده است.

۵- بحث

در این پژوهش، در گام نخست، مطالعات و پژوهش‌های گذشته مورد بررسی قرار گرفتند تا پرتکرارترین و موفق‌ترین روش‌های یادگیری ماشین در تشخیص بیماری‌های قلبی شناسایی شوند. پس از تحلیل این روش‌ها، مدل پیشنهادی که ترکیبی از شبکه عصبی پیچشی و الگوریتم تقویتی آدابوست است، طراحی و پیاده‌سازی شد. این ترکیب به دلایل متعددی می‌تواند در تشخیص بیماری‌های قلبی عملکرد بهتری نسبت به روش‌های دیگر داشته باشد. مهم‌ترین مزایای این روش عبارت‌اند از:

بهبود دقت تشخیص: ترکیب شبکه‌های عصبی پیچشی با الگوریتم آدابوست منجر به افزایش دقت تشخیص بیماری‌های قلبی می‌شود. آدابوست با تخصیص وزن‌های مناسب به نمونه‌های مختلف و تمرکز بر نمونه‌های دشوار، به کاهش نرخ خطای مدل کمک کرده و در نتیجه، عملکرد کلی مدل بهبود می‌یابد. در این پژوهش، دقت نهایی مدل پیشنهادی به ۸۹ درصد رسید که در مقایسه با مدل‌های پرتکرار یادگیری ماشین، یک بهبود قابل توجه محسوب می‌شود.

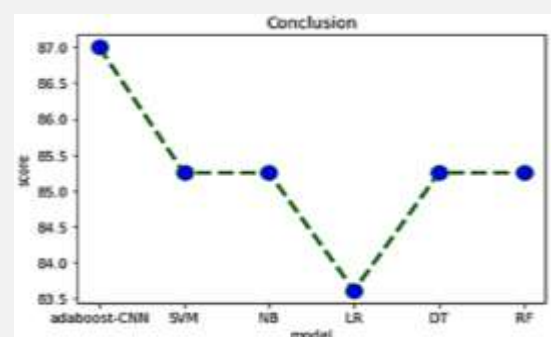
انتخاب ویژگی‌های مؤثر: آدابوست به دلیل توانایی بالای خود در انتخاب ویژگی‌های تمایزبخش، وزن بیشتری به نمونه‌های مهم‌تر اختصاص داده و تأثیر ویژگی‌های کم‌اهمیت را کاهش می‌دهد. این فرایند منجر به بهبود عملکرد مدل در تشخیص بیماری‌های قلبی شده و از پیچیدگی محاسباتی غیرضروری جلوگیری می‌کند.

افزایش تعمیم‌پذیری مدل: یکی از مشکلات رایج در شبکه‌های عصبی، بیش‌برازش است که در آن مدل به داده‌های آموزشی

جدول (۶) - نتایج پیش‌بینی بر اساس دقت.

ردیف	نام مدل	میزان دقت برحسب درصد
۱	ماشین بردار پشتیبان	۸۵/۲۵
۲	درخت تصمیم	۸۵/۲۵
۳	جنگل تصادفی	۸۵/۲۵
۴	رگرسیون لجستیک	۸۳/۶۱
۵	بیز ساده	۸۵/۲۵
۶	مدل پیشنهادی	۸۷

نمودار مقایسه نتایج پیش‌بینی مدل‌های پرتعداد با مدل پیشنهادی را می‌توان به صورت شکل ۹ مشاهده کرد.



شکل (۹) - نمودار همگرایی مدل بر اساس دقت.

برتری مدل پیشنهادی در مقایسه با سایر مدل‌ها کاملاً مشهود است و می‌توان از این مدل برای پیش‌بینی طبقه‌بندی‌های دوکلاسه استفاده کرد.

علاوه بر معیار دقت که ۸۷/۰ درصد گزارش شده، معیارهای صحت^۱، حساسیت یا فراخوانی^۲ و معیار F1- نیز محاسبه شده‌اند که نشان‌دهنده عملکرد مدل در دوکلاس هستند که به شرح جدول ۷ است:

جدول (۷) - نتایج پیش‌بینی مدل پیشنهادی.

کلاس	Precision	Recall	F1-Score
کلاس ۰	۰/۹۳	۰/۸۱	۰/۸۶
کلاس ۱	۰/۸۲	۰/۹۳	۰/۸۷

^۱ False Positive

^۲ False Negative

^۱ Precision

^۲ Recall

درحالی‌که در روش‌های سنتی، این فرآیند زمان بیشتری می‌طلبد.

امکان استفاده در کاربردهای واقعی: مدل پیشنهادی به دلیل ساختار ترکیبی خود، نه تنها دقت بالایی دارد، بلکه از لحاظ پردازشی نیز بهینه است. این امر باعث می‌شود که مدل در سیستم‌های پشتیبان تصمیم‌گیری پزشکی، اپلیکیشن‌های سلامت و حتی تجهیزات پوشیدنی برای نظارت بر وضعیت قلبی بیماران به کار گرفته شود.

وابسته شده و توانایی تعمیم‌دهی به داده‌های جدید را از دست می‌دهد. استفاده از آدابوست به‌عنوان یک روش تقویتی باعث می‌شود مدل، به جای حفظ الگوهای خاص داده‌های آموزشی، بتواند ویژگی‌های کلی‌تر و تعمیم‌پذیرتری را یاد بگیرد.

افزایش سرعت همگرایی: در فرآیند آموزش مدل، مشاهده شد که شبکه عصبی پیچشی به‌تنهایی پس از چندین اپوک به همگرایی می‌رسد، اما در ترکیب با آدابوست، این همگرایی سریع‌تر اتفاق می‌افتد. در این پژوهش، مدل پیشنهادی در ۵۰ اپوک آموزش داده شد و در دور ۲۵ به همگرایی رسید،

جدول (۸) - مزایا و معایب روش‌های یادگیری ماشین.

ردیف	مدل	معایب	مزایا
۱	بیز ساده	- پیچیدگی محاسباتی - قدرت پیش‌بینی محدود - وابستگی به داده‌های آموزش - اهمیت وزن‌دهی	- اجرای آن ساده و آسان است - به داده‌های آموزشی زیادی نیاز ندارد - مدیریت داده‌های از دست رفته - خطر کم بیش از حد برازش - به ویژگی‌های نامربوط حساس نیست - فهم ساده
۲	درخت تصمیم	- تطبیق بیش از حد - عدم تفسیرپذیری - حساسیت به تغییرات کوچک - تعصب نسبت به یک ویژگی خاص - عدم مدیریت در داده‌های از دست رفته	- کار کردن با داده‌های بزرگ و پیچیده - استفاده مجدد آسان - قابلیت ترکیب با روش‌های دیگر دارد. - ایجاد بیش‌برازش - دقت بالا - به خوبی در فضای با ابعاد بالا کار می‌کند. - حافظه بسیار کمتری استفاده می‌کند.
۳	ماشین بردار پشتیبان	- زمان یادگیری زیاد - مناسب مجموعه داده‌های بزرگ نیست. - در صورت وجود همپوشانی در کلاس‌ها، خوب کار نمی‌کند.	- تفسیر آسان - قدرت پیش‌بینی قوی - مقاوم در برابر بیش‌برازش - جنگل تصادفی از درخت تصمیم منفرد واریانس کمتری دارد. - جنگل‌های تصادفی بسیار انعطاف‌پذیر و دارای دقت بسیار بالایی هستند.
۴	آدابوست	- حساس به نویزها - مقیاس بندی سخت است	- تفسیر آسان - قدرت پیش‌بینی قوی - مقاوم در برابر بیش‌برازش - جنگل تصادفی از درخت تصمیم منفرد واریانس کمتری دارد. - جنگل‌های تصادفی بسیار انعطاف‌پذیر و دارای دقت بسیار بالایی هستند.
۵	جنگل تصادفی	- پیچیدگی بالایی دارد. - ساخت جنگل‌های تصادفی بسیار دشوارتر و زمان‌برتر از درختان تصمیم است. - به منابع محاسباتی بیشتری نیاز است. - روند پیش‌بینی با استفاده از جنگل‌های تصادفی در مقایسه با الگوریتم‌های دیگر بسیار وقت‌گیر است.	- جنگل تصادفی از درخت تصمیم منفرد واریانس کمتری دارد. - جنگل‌های تصادفی بسیار انعطاف‌پذیر و دارای دقت بسیار بالایی هستند.
۶	رگرسیون لجستیک	- در مسائل غیرخطی کاربرد ندارد. - نیاز به داده‌های آموزش زیاد دارد.	- به منابع محاسباتی زیادی احتیاج ندارد. - بسیار قابل تفسیر است. - اجرای آن بسیار آسان است و آموزش آن بسیار کارآمد است.
۷	شبکه عصبی پیچشی	- نیاز به داده‌های بزرگ - پیچیدگی محاسباتی - نیاز به آموزش مناسب - تفسیرپذیری مدل سخت - حساسیت به داده‌های ناقص و نویز	- قابلیت استخراج ویژگی خودکار - دقت بالا
۸	مدل پیش‌نهادی	- زمان آموزش مدل بالا - نیاز به انتخاب بهینه ابرپارامترها	- انتخاب بهترین ویژگی‌ها در نمونه‌های آموزشی - کاهش نویزها و افزایش مقیاس‌پذیری - کنترل عدم تعادل کلاس برای کسب نتیجه دقیق - سازگار شدن با مجموعه داده‌های کوچک

۶- نتیجه‌گیری

در این پژوهش، عملکرد مدل‌های مختلف یادگیری ماشین در پیش‌بینی بیماری قلبی مورد بررسی و مقایسه قرار گرفت. مدل‌های انتخاب‌شده شامل AdaBoost-CNN، SVM، NB،

ارتقا داد. استفاده از تکنیک‌هایی مانند افزایش داده (data augmentation) و حذف نویز می‌تواند به بهبود عملکرد مدل‌های یادگیری ماشین کمک کند. علاوه بر این، ترکیب مدل‌های مختلف به صورت مدل‌های ترکیبی و بررسی تأثیر ویژگی‌های جدید، می‌تواند به ارائه مدل‌هایی با دقت بالاتر منجر شود. همچنین، استفاده از روش‌های بهینه‌سازی هایپرپارامترها، مانند جستجوی شبکه‌ای (Grid Search) یا بهینه‌سازی بیزین (Bayesian Optimization)، می‌تواند موجب افزایش کارایی مدل شود.

علاوه بر این، پیشنهاد می‌شود که در پژوهش‌های آینده، مدل‌های یادگیری عمیق پیچیده‌تری مانند شبکه‌های حافظه بلندمدت-کوتاهمدت (LSTM) یا شبکه‌های عصبی بازگشتی (RNN) مورد بررسی قرار گیرند تا بتوانند وابستگی‌های زمانی موجود در داده‌های قلبی را بهتر تحلیل کنند. همچنین، بررسی عملکرد مدل‌ها در شرایط واقعی و استفاده از داده‌های بالینی متنوع‌تر از بیماران با ویژگی‌های گوناگون می‌تواند به افزایش تعمیم‌پذیری مدل‌ها کمک کند. توسعه سیستم‌های تشخیص هوشمند مبتنی بر این مدل‌ها و ارزیابی آن‌ها در محیط‌های پزشکی واقعی، گام مهمی در کاربرد عملی این روش‌ها خواهد بود.

۸- مراجع

- [1] Babatunde, O.A., et al., *10-year risk for cardiovascular diseases using WHO prediction chart: Findings from the civil servants in South-western Nigeria*. BMC Cardiovascular Disorders, 2020. **20**(1): p. 1-10.
- [2] Tanaka, H., *Exercise nonresponders: genetic curse, poor compliance, or improper prescription?* Exercise and sport sciences reviews, 2018. **46**(3): p. 137-137.
- [3] Sadr, H., et al., *Cardiovascular disease diagnosis: a holistic approach using the integration of machine learning and deep learning models*. European Journal of Medical Research, 2024. **29**(1): p. 455.
- [4] Elagizi, A., et al., *A Review of Obesity, Physical Activity, and Cardiovascular Disease*. Current Obesity Reports, 2020. **9**(4): p. 571-581.
- [5] Saberi, Z.A., H. Sadr, and M.R. Yamaghani. *An Intelligent Diagnosis System for Predicting Coronary Heart Disease*. in *2024 10th International Conference on Artificial Intelligence and Robotics (QICAR)*. 2024. IEEE.
- [6] Liang, T.-P., et al., *A web-based recommendation system for mobile phone selection*. PACIS 2007 Proceedings, 2007: p. 80.
- [7] Kalashami, M.P., M.M. Pedram, and H. Sadr, *EEG feature extraction and data augmentation in emotion recognition*. Computational

و DT, LR و RF بودند که بر اساس معیار دقت ارزیابی شدند. نتایج حاصل از این پژوهش نشان داد که مدل AdaBoost-CNN با دقت ۸۷ درصد بالاترین عملکرد را در پیش‌بینی بیماری قلبی دارد. این مدل، با بهره‌گیری از ترکیب یک شبکه عصبی کانولوشنال یک‌بعده (1D CNN) و الگوریتم AdaBoost، توانست دقت پیش‌بینی را به طور قابل توجهی نسبت به سایر مدل‌ها افزایش دهد. این ترکیب باعث شد که مدل از مزایای هر دو روش بهره‌بردارد، به این صورت که CNN قابلیت استخراج ویژگی‌های پیچیده از داده‌های پزشکی را داشت و AdaBoost با تقویت مدل پایه، دقت پیش‌بینی را بهبود بخشید.

یافته‌های این پژوهش همچنین نشان داد که انتخاب مدل مناسب برای پیش‌بینی بیماری قلبی وابسته به ویژگی‌های داده، اندازه مجموعه داده و نیازمندی‌های خاص مسئله است. مدل AdaBoost-CNN به دلیل قدرت بالای شبکه عصبی کانولوشنال در استخراج ویژگی‌های غیرخطی و عمیق از داده‌های پزشکی و توانایی الگوریتم AdaBoost در بهبود عملکرد مدل پایه، به عنوان بهترین گزینه در این مطالعه انتخاب شد. علاوه بر این، مقاومت بالای AdaBoost در برابر نویز و داده‌های پرت از دیگر عواملی بود که سبب برتری این مدل نسبت به سایر روش‌های بررسی‌شده گردید. از آن‌جا که داده‌های پزشکی اغلب دارای نویز و ناپیوستگی‌های آماری هستند، عملکرد مطلوب AdaBoost-CNN در برابر چنین چالش‌هایی اهمیت ویژه‌ای پیدا می‌کند.

در نهایت، نتایج این پژوهش می‌تواند به عنوان یک راهنمای علمی و عملی برای انتخاب مدل‌های یادگیری ماشین در حوزه پزشکی مورد استفاده قرار گیرد. این یافته‌ها می‌توانند در توسعه سیستم‌های هوشمند تشخیص بیماری‌های قلبی و همچنین بهینه‌سازی ابزارهای پیش‌بینی و پایش وضعیت بیماران نقش مهمی ایفا کنند. با توجه به رشد روزافزون فناوری‌های مبتنی بر هوش مصنوعی در علوم پزشکی، چنین مدل‌هایی می‌توانند به کاهش خطاهای تشخیصی، بهبود فرآیند تصمیم‌گیری بالینی، و افزایش دقت تشخیص بیماری‌های قلبی کمک شایانی نمایند.

۷- پیشنهادها

با وجود عملکرد قابل توجه AdaBoost-CNN، همچنان امکان بهبود دقت پیش‌بینی وجود دارد. در پژوهش‌های آینده، می‌توان با بهبود روش‌های پیش‌پردازش داده‌ها و افزایش حجم داده‌های آموزشی، دقت مدل‌های پیش‌بینی بیماری قلبی را



- and machine learning techniques. Health and Technology, 2020. **10**(5): p. 1137-1144.
- [22] Austin, P.C., et al., *Using methods from the data-mining and machine-learning literature for disease classification and prediction: a case study examining classification of heart failure subtypes*. Journal of clinical epidemiology, 2013. **66**(4): p. 398-407.
- [23] H, K., J. H, and G. J, *Diagnosing Coronary Heart Disease using Ensemble Machine Learning*. International Journal of Advanced Computer Science and Applications, 2016. (10).
- [24] Baccouche, A., et al., *Ensemble deep learning models for heart disease classification: A case study from Mexico*. Information (Switzerland), 2020. **11**(4): p. 207-207.
- [25] Raj, A., et al., *Heart Disease Prediction using Machine Learning*. 2023 9th International Conference on Signal Processing and Communication, ICSC 2023, 2023. **9**(O4): p. 113-119.
- [26] Shafiinejad, E. *A study on data-level balancing methods in supervised learning approaches*.
- [27] Mohammed, A. and R. Kora, *A comprehensive review on ensemble deep learning: Opportunities and challenges*. Journal of King Saud University - Computer and Information Sciences, 2023. **35**(2): p. 757-774.
- [28] Aggarwal, C.C., *Advanced Topics in Deep Learning*. 2018. 419-458.
- [29] Appaji, S.V.s., et al., *Movie Recommendation System Using Machine Learning*. AIP Conference Proceedings, 2023. **2794**(1): p. 84-98.
- [30] Zhang, Q., J. Lu, and Y. Jin, *Artificial intelligence in recommender systems*. Complex & Intelligent Systems, 2021. **7**(1): p. 439-457.
- [31] Brubaker, P.H. and C. Ozemek, *Exercise therapy for the failing heart :Harmful or helpful?* ACSM's Health and Fitness Journal, 2010. **14**(2): p. 9-15.
- [32] Abzari, M., et al., *The effect of internal marketing on market orientation and organizational performance in Hotel industry*. Journal of Business Management Perspective, 2009. **۸** (۳۱): p. 25-42. (In Persian).
- [33] Aha, D. and D. Kibler, *Instance-based prediction of heart-disease presence with the Cleveland database*. University of California, 1988. **3**(1): p. 3.2.
- [34] Lotfi, R., et al., *An extended robust mathematical model to project the course of COVID-19 epidemic in Iran*. Annals of Operations Research, 2022: p. 1-25.
- intelligence and neuroscience, 2022. **2022**(1): p. 7028517.
- [8] Ferretto, L.R., et al., *A Physical Activity Recommender System for Patients with Arterial Hypertension*. IEEE Access, 2020. **8**: p. 61656-61664.
- [9] Sarker, I.H., *Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions*. SN Computer Science, 2021. **2** (۶): p. 420-420.
- [10] Malekyian Fini, E. and S. Ahmadi, *Effect of Resistance Exercise and Training and Principles of Prescribing it for Cardiovascular Patients*. Journal of Shahid Sadoughi University of Medical Sciences, 2021.
- [11] Vazan, M., *Deep Learning: From Basics to Building Deep Neural Networks with Python*. 2022. 1-205.
- [12] Sajja, G.S., et al. *Towards Application of Machine Learning in Classification and Prediction of Heart Disease*.
- [13] Nazari, M., et al., *Design and analysis of a telemonitoring system for high-risk pregnant women in need of special care or attention*. BMC Pregnancy and Childbirth, 2024. **24**(1): p. 817.
- [14] Deilami, F.M., H. Sadr, and M. Nazari, *Using Machine Learning Based Models for Personality Recognition*. Big Data and computing visions, 2022. **1**(3): p. 128-139.
- [15] Nazari, M., et al., *Detection of Cardiovascular Diseases Using Data Mining Approaches: Application of an Ensemble-Based Model*. Cognitive Computation, 2024: p. 1-15.
- [16] Adavi, Z., et al., *Machine Learning-Based Estimation of Hourly GNSS Precipitable Water Vapour*. Remote Sensing, 2023. **15**(18): p. 4551-4551.
- [17] Dey, A., J. Singh, and N. Singh, *Analysis of Supervised Machine Learning Algorithms for Heart Disease Prediction with Reduced Number of Attributes using Principal Component Analysis*. International Journal of Computer Applications, 2016. **140**(2): p. 27-31.
- [18] Long, N.C., P. Meesad, and H. Unger, *A highly accurate firefly based algorithm for heart disease prediction*. Expert Systems with Applications, 2015. **42**(21): p.8221-8231.
- [19] Mazaheri, S., M. Ashoori, and Z. Bechari, *A Model to Predict Heart Disease Treatment Using Data Mining*. Payavard-Salamt, 2017. **11**(3): p. 287-296.
- [20] Thomas, J. and R.T. Princy. *Human heart disease prediction system using data mining techniques*. in 2016 international conference on circuit, power and computing technologies (ICCPCT). 2016. IEEE.
- [21] Tougui, I., A. Jilbab, and J. El Mhamdi, *Heart disease classification using data mining tools*