

Original article



Diagnosing Heart Disease Using Convolutional Neural Network and the Particle Swarm Optimization

Sara Motamed¹, Elham Askari^{1*}

1. Assistant Professor, Department of Computer Engineering, Fouman and Shaft Branch, Islamic Azad University, Fouman, Iran

ARTICLE INFO:

Article History:

Received: 9 Jan 2024

Accepted: 29 May 2024

Published: 20 Jun 2024

*Corresponding Author:

Elham Askari

Email:

askari.elham@iau.ac.ir

Citation: Motamed S, Askari E. Diagnosing Heart Disease Using Convolutional Neural Network and the Particle Swarm Optimization. Journal of Health and Biomedical Informatics 2024; 11(1): 26-42. [In Persian]

Abstract:

Introduction: The human heart is a physiologically vital organ whose signals can be continuously recorded using an electrocardiogram (ECG) device. Cardiovascular diseases are one of the leading causes of mortality worldwide. Timely and accurate identification of this condition, along with preventive measures, can help reduce the incidence of cardiovascular diseases.

Method: This article aimed to predict a group of heart failures based on the patterns found in extracted features from patients with cardiac arrhythmias, distinguishing them from samples in a normal state. The proposed model involves preprocessing operations, such as discretization and replacement of missing values using column-wise averaging, on the dataset. Subsequently, feature selection operations were performed on normalized data to reduce complexity and improve speed and accuracy. The data is then fed into decision tree classifiers, k-nearest neighbors, naive Bayes, and convolutional neural networks.

Results: A comparison of the accuracy obtained from different algorithms before and after applying the proposed method reveals improved performance across all methods after implementation. Particularly, the convolutional neural network demonstrates superior performance.

Conclusion: Based on the results, it can be concluded that the proposed model achieves an accuracy of 92.34%, surpassing other methods.

Keywords: Cardiac Arrhythmia, Convolutional Neural Network, Particle Swarm Optimization, Multiclass Classification

© 2024 The Author(s); Published by Kerman University of Medical Sciences. This is an open-access article distributed under the terms of the Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0/>), which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cite



CrossMark

مقاله پژوهشی

تشخیص بیماری قلبی با استفاده از شبکه‌های عصبی پیچشی و الگوریتم بهینه‌سازی ذرات

سارا معتمد^۱، الهام عسکری^{۱*}

۱. استادیار، دکترای مهندسی کامپیوتر، گروه کامپیوتر، واحد فومن و شفت، دانشگاه آزاد اسلامی، فومن، ایران

چکیده:

مقدمه: قلب انسان از لحاظ فیزیولوژیکی یک شاخص زنده محسوب می‌گردد و امکان ثبت سیگنال‌ها به صورت مداوم با استفاده از دستگاه الکتروکاردیوگرام وجود دارد. بیماری‌های قلبی - عروقی یکی از مهم‌ترین علت‌های مرگ‌ومیر در کل دنیا محسوب می‌شوند. متلا شدن به بیماری‌های قلبی-عروقی می‌تواند قابل اجتناب باشد، البته در صورتی که بتوان سریع و دقیق این بیماری را پیش‌بینی یا شناسایی کرد و در جهت جلوگیری اقدام نمود.

روش کار: در این مطالعه با هدف تشخیص الگوهای موجود در ویژگی‌های استخراج شده از بیماران آریتمی قلبی، گروهی از نارسایی‌های قلبی پیش‌بینی خواهد شد و نمونه‌های بیمار را از حالت عادی تشخیص می‌دهد. در مدل پیشنهادی ابتدا روی مجموعه دادگان، در مرحله پیش‌پردازش، عملیات گسسته‌سازی و جایگزینی مقادیر از دست رفته به روش میانگین‌گیری ستونی انجام می‌شود، سپس به منظور کاهش ویژگی‌ها، پیچیدگی و افزایش سرعت و دقت، عملیات انتخاب ویژگی، روی داده‌های نرمال شده صورت گرفته و به طبقه‌بندی درخت تصمیم، k نزدیک‌ترین همسایه، بیز ساده و CNN ارسال می‌شود.

یافته‌ها: در مقایسه‌ای که از دقت به‌دست آمده از الگوریتم‌های مختلف قبل و بعد از اعمال روش پیشنهادی انجام شده است مشاهده می‌شود که کلیه روش‌ها پس از اعمال روش پیشنهادی، با دقت بهتری عمل می‌کنند همچنین CNN عملکرد بهتری از خود نشان داده است.

نتیجه‌گیری: نتایج نشان داد که دقت مدل پیشنهادی با نرخ تشخیص ۹۲/۳۴ درصد بهتر از سایر روش‌ها عمل می‌نماید.

کلیدواژه‌ها: آریتمی قلب، شبکه‌های عصبی پیچشی، بهینه‌سازی ازدحام ذرات، طبقه‌بندی چند کلاس

اطلاعات مقاله:

سابقه مقاله:

دریافت: ۱۴۰۲/۱۰/۱۹

پذیرش: ۱۴۰۳/۳/۹

انتشار برخط: ۱۴۰۳/۳/۳۱

*نویسنده مسئول:

الهام عسکری

ایمیل:

askari.elham@iau.ac.ir

ارجاع:

معتمد سارا، عسکری الهام. تشخیص بیماری قلبی با استفاده از شبکه‌های عصبی پیچشی و الگوریتم بهینه‌سازی ذرات. مجله انفورماتیک سلامت و زیست پزشکی ۱۴۰۳؛ ۱۱(۱): ۲۶-۴۲.



مقدمه

امروزه در حوزه پزشکی، جمع‌آوری داده‌ها و بررسی بیماری‌های مختلف مطالعات زیادی انجام شده است. منابع داده‌ای در حوزه سلامت حاوی میزان وسیعی از داده‌های بالینی است که با توجه به ظهور نظام اطلاعات یکپارچه و رشد فن‌آوری اطلاعات این مهم بیش از پیش نمایان شده است. قابل توجه است که حجم داده‌های جمع‌آوری شده، بسیار بالا است و برای این که بتوان از بین این حجم انبوه داده‌ها، الگوها و نتایج مورد نظر را به دست آورد، باید از تکنیک‌های هوش مصنوعی استفاده کرد. هوش مصنوعی و در ادامه آن داده کاوی از جمله پیشرفت‌های فن‌آوری در راستای مدیریت داده‌ها است و استفاده گسترده از سیستم‌های اطلاعات و پایگاه‌های داده، ادغام آن با شیوه‌های سنتی را به یک الزام تبدیل کرده است [۱]. در سال‌های اخیر میزان بالای ابتلا به بیماری قلبی و عروقی و تعداد بالای مرگ و میر ناشی از بیماری قلبی در سراسر جهان این مسئله را به یکی از نگرانی‌های صنعت بهداشت و درمان تبدیل کرده است. در واقع قلب و سیستم انتقال خون، از مهم‌ترین ارگان‌های بدن انسان می‌باشند. هر اختلالی در این ارگان‌ها بر روی عملکرد کل بدن تأثیر بسیار محسوسی دارد، زیرا سیستم انتقال خون مسئول تأمین انرژی مورد نیاز تمام ارگان‌های بدن (از جمله خود قلب) است [۲]. بر اساس گزارش سازمان جهانی بهداشت، بیماری‌های قلبی-عروقی، اولین بیماری غیرواگیر است که باعث مرگ و میرهای متعدد در جهان می‌شود. در سال ۲۰۲۰، طی یک مطالعه توسط سازمان بهداشت جهانی تخمین زده شد که بیش از ۱۷ میلیون نفر بر اثر بیماری‌های قلبی-عروقی جان خود را از دست داده‌اند که این امر نشان دهنده بیش از ۴۰ درصد از مرگ و میرها در سراسر جهان است [۲].

همچنین مطالعات نشان داده‌اند که بیش از ۷۰ درصد مرگ و میرها در کشورهای کم درآمد و متوسط رخ می‌دهد. مرگ و میر بر اثر بیماری قلبی در ایران به عنوان مهم‌ترین چالش نظام سلامت کشور، موجب بیش از یک سوم کل مرگ‌ها است و سوانح و حوادث و سرطان در رتبه‌های دوم و سوم علل مرگ در ایران هستند [۱]. پیش بینی شده است بیماری‌های قلبی و عروقی تنها علت اصلی مرگ در جهان باقی بماند [۳]. از طرف دیگر، از پایان سال ۱۳۹۸ شاهد فراگیر شدن بیماری فراگیر کرونا هستیم و با توجه به بررسی‌های صورت گرفته، بیشتر مبتلایان به این بیماری دارای بیماری‌های زمینه‌ای از جمله فشارخون بالا، اختلالات قلبی و عروقی و دیابت هستند و میزان مرگ و میر در این افراد نسبت به دیگر مبتلایان بیشتر است [۴]. در واقع، افرادی که دچار بیماری قلبی و عروقی هستند در مقابل سایر بیماری‌ها نیز به شدت آسیب‌پذیر خواهند بود؛ لذا لازم است افراد جامعه به خصوص گروه‌های پرخطر مورد غربالگری قرار گیرند تا میزان ابتلا به بیماری قلبی را بتوان کنترل کرد و یا از وخیم شدن بیماری جلوگیری کرد تا میزان مرگ و میر کاهش یابد. این مسئله زمانی امکان‌پذیر است که بتوان شرایط جسمی افراد را مورد پایش قرار داد و تمهیدات لازم جهت پیش‌بینی ابتلای افراد به بیماری با توجه به شرایط بالینی و پزشکی افراد را به کار برد تا بتوان بیماری را در مرحله اولیه و حتی قبل از بروز شواهد و علائم تشخیص داد. این امر می‌تواند سبب کاهش بروز و شیوع این گونه بیماری‌ها باشد [۵]؛ بنابراین می‌توان از فناوری‌های هوش مصنوعی در سیستم‌های مراقبت‌های بهداشتی برای پیش‌بینی بیماری قلبی استفاده کرد [۶].

در این راستا هدف این پژوهش به کارگیری روش‌های هوش مصنوعی و پیرو آن یادگیری عمیق در پیش‌بینی بیماری‌های مرتبط با آریتمی قلبی است تا پزشکان و مراکز بهداشتی و درمانی بتوانند با استفاده از آن‌ها به راهکارهایی برای تشخیص زودهنگام بیماری دست یابند. در واقع، خلاف دستگاه‌های پزشکی مانند مانیتور قلب که علائم حیاتی فرد را مورد بررسی قرار می‌دهد، هوش مصنوعی می‌تواند اطلاعات این دستگاه را جمع‌آوری کرده و پس از تجزیه و تحلیل متوجه شرایط پیچیده‌تری مانند خطراتی که بیمار را در آینده تهدید می‌کند، شود. در این راستا، هدف این مطالعه نیز ارائه مدلی مبتنی بر روش‌های یادگیری عمیق به منظور پیش‌بینی فاکتورهای مؤثر بر بیماری‌های قلبی و عروقی جهت تشخیص زودهنگام این بیماری است. با بررسی‌ها و تحقیقات انجام شده می‌توان به این نتیجه رسید که طبقه‌بندی سیگنال‌های قلبی دارای چالش‌هایی از جمله اعمال تکنیک‌های پیش‌پردازش اطلاعات مانند هرس کردن، انتخاب ویژگی‌ها، مدیریت مقدار گمشده برای بهبود کارایی مسئله طبقه‌بندی چند برچسب، مدیریت ویژگی پیوسته در مسئله طبقه‌بندی چند برچسب، استخراج مجموعه ویژگی‌ها و غیره می‌باشد؛ لذا در این پژوهش هدف از بین بردن این چالش‌ها و کارا شدن الگوریتم پیشنهادی جهت تشخیص بیماران قلبی می‌باشد.



بیماری قلبی، یک رده از بیماری است که قلب یا عروق را درگیر می‌کند و شامل تنگی یا انسداد عروق کرونر می‌باشد که به دلیل وجود رسوب کلسترول و چربی بر روی دیواره‌های داخلی شریان‌ها ایجاد می‌شود. این پلاک‌ها می‌توانند جریان خون را به عضله قلب محدود کنند. اگر در عضله قلب هیچ جریان خونی وجود نداشته باشد و یا جریان خون بسیار ضعیف وجود داشته باشد، منجر به سکتة قلبی (MI(Myocardial Infarction) و یا انفارکتوس حاد عضله قلب (AMI(Acute Myocardial Infarction) می‌شود که معمولاً به عنوان حمله قلبی شناخته شده است؛ بنابراین به صورت خلاصه می‌توان گفت اختلالات قلب و رگ‌ها منجر به بیماری‌هایی نظیر کرونر قلبی، از کار افتادن قلب، ایست قلبی، آریتمی بطنی، ایست ناگهانی قلب، سکتة ایسکمیک، حمله ایسکمیک گذرا، بیماری رماتیسم قلبی، بیماری عروق محیطی و بیماری‌های قلبی مادرزاد می‌شود. بیماری‌های قلبی اصطلاح جمعی برای انواع بیماری‌های مؤثر بر قلب است. بیماری قلبی با علل مختلفی چون خصوصیات ژنتیکی، عادت‌ها، رفتارها و رژیم غذایی ناصحیح به عنوان یکی از خطرناک‌ترین و شایع‌ترین بیماری‌ها در زندگی انسان‌ها است، بسیاری از مردم نمی‌دانند که رفتار نادرست آن‌ها به آرامی به سیستم قلبی و عروقی صدمه می‌زند [۴]. بسیاری از بیماری‌های قلبی با فشارخون بالا باعث کمک به سفت شدن سرخرگ‌ها می‌شوند. سطح بالای کلسترول بد در شریان‌ها ناشی از رژیم غذایی کنترل نشده با سطح بالایی از چربی‌های اشباع شده، می‌تواند روی دیواره‌های داخلی عروق کرونر فشار وارد کند. همه این‌ها به‌اضافه تشکیل ضایعات و انسداد، آسیب لایه داخلی رگ‌های خونی را شامل می‌شود و مانع از حمل و نقل اکسیژن و تغذیه به قلب شده به طوری که قلب نمی‌تواند مقدار کافی از خون را پمپاژ کند و در نتیجه افراد در معرض خطر بالاتری از حمله قلبی قرار می‌گیرند. به دست آوردن راه‌های آسان‌تر برای تشخیص بیماری‌های قلبی و به‌صورت سریع، برای نجات جان بیمار بسیار حیاتی است. روش‌های داده‌کاوی برای درمان بیماری‌های قلبی می‌تواند عملکرد قابل‌اعتمادتری در تشخیص بیماران مبتلا به بیماری قلبی ارائه دهد. پس از نمونه‌گیری‌های مختلف از بیمار توسط دستگاه‌ها و استخراج ویژگی‌ها، شرایط تصمیم‌گیری محیا می‌شود. الکتروکاردیوگرام روش اصلی برای نظارت بر فعالیت قلب در انسان است. موج الکتروکاردیوگرام زیر موج‌های معینی را در بر می‌گیرد که شامل موج‌های P، Q، R، S و T می‌باشد. ویژگی‌های معینی از این امواج از جمله نقاط اوج سیگنال، طول و فاصله بین دو موج، اطلاعات کلیدی را برای تشخیص هر گونه اختلال فراهم می‌کنند. آریتمی در بیماری‌های قلبی ناشی از اختلال در ریتم ضربان قلب منظم اتفاق می‌افتد و ضربان قلب بسیار سریع یا بسیار کند باعث کاهش عملکرد قلب در پمپاژ خون می‌شود [۵].

انواع مختلف آریتمی وجود دارد که برخی از آن‌ها تهدید کننده زندگی هستند و باعث مرگ فوری می‌شوند؛ بنابراین طبقه‌بندی آریتمی می‌تواند نقش مهمی در نظارت بر بیماران قلبی داشته باشد. در راستای تحقیقات پیش‌بینی بیماری‌های قلبی، پژوهش‌های بسیاری در این زمینه صورت گرفت که نتیجه آن منجر به تولید تکنیک‌های مختلفی جهت تشخیص زودهنگام بیماری قلبی می‌شود. فریدونی و همکاران با هدف طراحی و شبیه‌سازی سیستمی بیوالکتریک با قابلیت آموزش‌پذیری جهت تشخیص بیماری‌های آریتمی از شبکه عصبی پیچشی پرسپترون چند لایه استفاده کردند [۷]. ناروئی و همکاران از تحلیل مؤلفه اساسی، مؤلفه اول به عنوان ورودی به شبکه عصبی پیچشی (CNN (Convolutional Neural Network) با دو لایه پنهان که هر لایه ۱۰۰ نرون استفاده کرده و در طبقه‌بندی دودویی به دقت ۹۳٪/۴۰ و برای طبقه‌بندی چندکلاسه به دقت ۷۸٪ دست یافتند. ناروئی و همکاران از روش فیشر برای استخراج ویژگی‌های مهم استفاده کردند. ویژگی‌های استخراج شده به عنوان ورودی طبقه‌بند SVM انتخاب شدند. با توجه به نتایج برای طبقه‌بندی دودویی به دقت ۹۷٪/۱۴ درصد و برای طبقه‌بندی چندکلاسه به دقت ۹۰٪/۱۷ گزارش شده است [۸].

دشتی نژاد و همکاران در پژوهشی تحت عنوان «تشخیص بیماری کبدی و قلبی از طریق عنیبه‌شناسی مبتنی بر شبکه پس انتشار خطا» به بررسی پیش‌بینی و تشخیص بیماری قلبی پرداختند. هدف اصلی این مطالعه بررسی تشخیص بیماری از طریق عنیبه‌شناسی به وسیله شبکه‌های پس انتشار خطا که با استفاده از ساختار چشم و همچنین وجود مکانیزمی جهت تشخیص دقیق موقعیت عنیبه و تطبیق با الگوی عنیبه‌شناسی به بررسی دقیق مکان‌ها پرداخته شده است، بود. بدین گونه که نرم‌افزار ارائه شده از طریق تشخیص لبه به بررسی دقیق بافت عنیبه و سپس به تجزیه و تحلیل ناحیه موردنظر بر حسب نوع بیماری می‌پردازد و در آخر یادگیری و پیش‌بینی در حوزه سلامت را مورد ارزیابی قرار می‌دهد [۹].



Awang و Palaniappan سیستم‌پیش بینی بیماری به نام قلب هوشمند را با استفاده از تکنیک‌های داده کاوی درخت تصمیم، شبکه بیز و CNN توسعه دادند. این سیستم به سؤالات پیچیده پزشکی بر مبنای اگر و آن‌گاه پاسخ می‌دهد در حالی که سیستم‌های سنتی نمی‌توانند به این سؤالات پاسخ دهند. سیستم مورد نظر مبتنی بر وب، کاربرپسند، مقیاس پذیر، قابل اعتماد و قابل ارتقاء بوده و با استفاده از داده کاوی روی پارامترهای پزشکی از قبیل: سن، جنسیت، فشارخون، قند خون و غیره می‌توان احتمال بیمار شدن به بیماری‌های قلبی را پیش‌بینی کرد [۱۰]. Shivsankar و Venkatalakshmi به طراحی و تشخیص سیستمی برای پیش‌بینی بیماری قلبی مبتنی بر تکنیک‌های داده کاوی پرداختند. مقدار $84/01$ درصد برای صحت مدل ایجاد شده با درخت تصمیم حاصل گردید [۱۱]. Masethe و همکارش به ارائه سیستمی برای پیش‌بینی حمله قلبی با صحت 99% پرداختند. پارامترهای مورد بررسی شامل: جنسیت، سن، نوع درد قفسه سینه، افزایش ضربان قلب، کلسترول، سیگاری بودن، قند خون، فشارخون، نوع دستگاه ثبت ضربان قلب، رژیم غذایی و الکل بود [۱۲]. مدل آن‌ها با انتخاب بهترین ویژگی‌ها با استفاده از الگوریتم بسته‌بندی پیرامون جنگل تصادفی کار می‌کند و به دنبال آن، طبقه‌بندی‌های مختلف یادگیری ماشین، بر روی ویژگی‌های انتخاب شده اجرا می‌شود. از داده‌های آریتمی قلبی از دانشگاه کالیفرنیا، مخزن یادگیری ماشین ارواین (University of California Irvine) برای هدف تجربی استفاده شده است. پس از نرمال‌سازی داده‌ها، اعتبارسنجی متقابل ۱۰ مرحله‌ای بر روی ماشین بردار پشتیبانی (Support Vector Machine)، K نزدیک‌ترین همسایه (K-Nearest Neighbor)، بیز ساده، جنگل تصادفی و پرسپترون چند لایه اعمال شد. نتایج تجربی نشان داد که Multi-Layer Perceptron با به دست آوردن دقت متوسط $87/26\%$ ، طبقه‌بندی‌های دیگر را کنار می‌زند، در حالی که دقت محاسبه شده برای KNN و SVM به ترتیب $76/6\%$ و $74/4\%$ است، که پایین‌تر از طبقه‌بند MLP است [۱۳]. Zhang و Zhou [۱۴] به منظور کاهش بعد، روش (Multi-label Dimensionality Reduction via Dependence Maximization) MDDM با استفاده از حداکثرسازی وابستگی را پیشنهاد دادند. این روش شامل یک روش کاهش بعد (Principal component analysis) می‌شود که برای دامنه چند برچسب، هدف گزاری شده است. این روش یک رتبه‌بندی از ویژگی‌ها را به وسیله حداکثرسازی وابستگی بین ویژگی‌ها و برچسب‌های کلاس مربوط به کلاس با استفاده از معیار وابستگی شناخته شده ایجاد می‌کند. استراتژی‌های فیلتر نیز می‌توانند زیرمجموعه‌ای از ویژگی‌ها را به جای ویژگی‌های تنها در نظر بگیرند. پس از تعدادی تکرار، زیرمجموعه ویژگی با بهترین مقدار معیار انتخاب می‌شود. مانند سایر تکنیک‌های انتخاب ویژگی چند برچسب، فرآیند بعدی می‌تواند برای ارائه داده‌های چند برچسب اصلی با ویژگی‌های انتخاب شده، استفاده شود. Yu و Kong [۱۵] تکنیک انتخاب ویژگی چندبرچسب جدیدی را برای طبقه‌بندی گراف پیشنهاد دادند. این تکنیک بر اساس جستجوی کارآمد برای ویژگی‌های زیرگراف بهینه در اشیای گراف با برچسب‌های چندگانه است و هر زیر مجموعه را با یک معیار خاص ارزیابی می‌کند. نتایج حاصل از به کارگیری این روش پیشنهادی بسیار موفق بوده است.

محمود و همکاران جهت تشخیص زودهنگام بیماری قلبی پس از جمع‌آوری مجموعه داده برای رفع مقادیر گم‌شده و حذف نویز و انتخاب ویژگی از روش لاسو استفاده نمودند. سپس ۱۴ ویژگی انتخاب شده وارد شبکه CNN شدند. نوع تقسیم داده‌ها به صورت 30% در گروه آموزش و 70% در گروه آزمون مشخص شد. ساختار شبکه شامل یک لایه تمام متصل با ۶۴ نورون - شامل لایه دنس، لایه دراپ اوت با مقدار $0/15\%$ به همراه تابع فعال‌ساز آر. ای. ال. یو - دو لایه کانولوشن و یک لایه تماماً متصل است. در لایه کانولوشن اول، دو فیلتر و دو لایه پولینگ میانگین به همراه تابع فعال‌ساز مشاهده شد. در لایه دوم از چهار فیلتر و چهار پولینگ میانگین با مشخصات قبل استفاده شد. سپس خروجی تولید شده وارد یک لایه تمام متصل دارای ۵۱۲ نورون و پارامترهایی نظیر لایه متصل اول گردید. سپس وارد لایه دنس شده و پس از تولید خروجی، شبکه طراحی شده در دو حالت مورد آزمون قرار می‌گیرد. در حالت اول کلاس تشخیص بیماری است که با اعداد ۰ و ۱ تعیین می‌شود و در حالت دوم شبکه خروجی را در حالت چهار کلاسه مورد بررسی قرار می‌دهد که بر اساس نوع علائم، فرد را در کلاس بیماری‌های قلبی مختلف جای می‌دهد. در این پژوهش دقت شبکه در کلاس باینری به میزان 97% و در حالت ۶ کلاس به دقت 86% دست یافت [۱۶].



Shaji جهت پیش بینی بیماری قلبی از ۴ تکنیک ماشین بردار پشتیبان، جنگل تصادفی، نزدیک ترین همسایه و شبکه عصبی برای پیش بینی استفاده نمودند. برای حل موضوع داده‌هایی با حجم کم، از حدود ۲۲۰۰ بیمار، ۲۰ ویژگی انتخاب شده که پس اعمال طبقه‌بندی و ارزیابی، شبکه عصبی با دقت ۹۲ درصد درست‌ترین پیش بینی را داشت. در این تحقیق از شبکه عصبی پیشخور استفاده شده است [۱۷]. Anggoro و Kurnia برای بهبود تشخیص زودهنگام بیماری قلبی از دو تکنیک ماشین بردار پشتیبان و نزدیک ترین همسایه استفاده نمودند و مجموعه داده آن شامل ۳۰۴ نمونه با ۱۴ ویژگی است که نتیجه آن نشان دهنده برتری الگوریتم ماشین بردار پشتیبان است [۱۸].

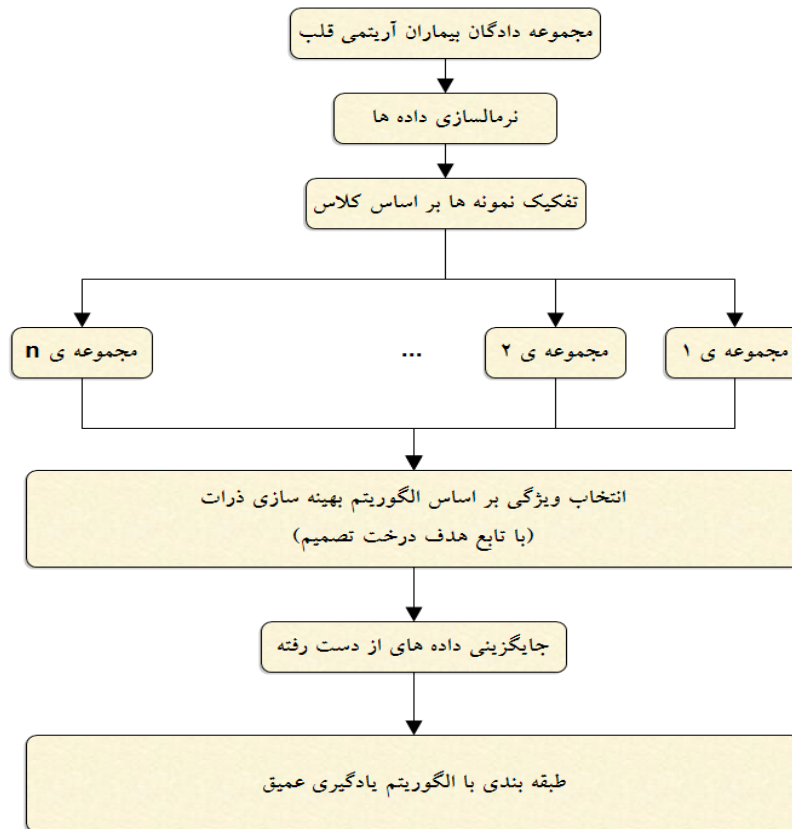
Kumar و Singh، جهت پیش بینی بیماری قلبی، دقت عملکرد چهار الگوریتم ماشین بردار پشتیبان، درخت تصمیم، رگرسیون خطی و نزدیک ترین همسایه در تشخیص بیماری قلبی را مورد بررسی قرار دادند. مقدار نمونه‌های تحت بررسی از مخزن داده کیولند دارای ۳۰۳ نمونه با ۷۵ ویژگی بوده که از میان آن‌ها ۱۳ ویژگی مناسب به همراه یک صفت هدف استخراج شد. در ابتدا برای حل مسئله طبقه‌بندی داده‌ها، ارزش‌ها به صورت ۰ و ۱ نرمال‌سازی شد و سپس الگوریتم‌های طبقه‌بندی روی داده‌ها اعمال شدند و بر اساس معیار دقت الگوریتم نزدیک ترین همسایه با دقت ۸۷٪ توانست نسبت به سایر الگوریتم‌ها برتری داشته باشد. این طبقه‌بندی کننده بر اساس فاصله بین مکان داده‌ها کار می‌کند و برای داده‌های غیرخطی مناسب است. از لحاظ معایب باید گفت به دلیل این که از همه داده‌های آموزشی استفاده می‌کند، موجب می‌شود از لحاظ محاسباتی کمی گران باشد و در مقایسه با سایر الگوریتم‌های یادگیری با نظارت، نیازمند حافظه ذخیره‌سازی بالایی است و در صورت داشتن مقدار کا بزرگ، پیش‌بینی آهسته خواهد بود و نسبت به مقیاس داده و ویژگی‌های نامرتب حساس است [۱۹]. Khan از مجموعه داده کیولند و مجموعه داده بهداشت عمومی و مجموعه داده‌های ثبت شده توسط حسگر برای ارائه روش شبکه عصبی اصلاح شده، استفاده نمود. برای انتخاب ویژگی از الگوریتم بهینه‌سازی ازدحام ذرات بهره‌گیری شد. پس از مرحله آموزش، اطلاعات حس شده در سرور ابری مورد آزمایش قرار گرفت تا اگر نتیجه غیرعادی باشد، یک پیام هشدار به پزشک معالج فرستاده شود. ترکیب دو الگوریتم شبکه عصبی یادگیری عمیق و الگوریتم بهینه‌سازی تطبیقی باعث به وجود آمدن شبکه پیشنهادی شد که دقت آن ۹۸٪ است [۲۰]. Dutta و همکاران برای بهبود پیش‌بینی بیماری قلبی از یک CNN استفاده نمودند که در ابتدا ویژگی‌ها توسط الگوریتم لاسو (Lasso Algorithm) انتخاب شده و سپس ۵۰ ورودی وارد یک لایه تمام متصل می‌شوند که در آن ۶۴ نورون و بایاس ترکیب شده به همراه یک تابع فعال‌ساز آر.ای.ال.یو (RELU) و یک دراپ اوت (drop out) که ۲۰٪ بیش برآزش را کاهش می‌دهد، قرار دارند. در لایه اول دو فیلتر و یک پولینگ میانگین استفاده شده و در لایه دوم، چهار فیلتر و مشخصات قبل اعمال شد. معماری پیشنهادی شامل ۳۲۶۴۲ پارامتر آموزشی و ۱۱۶۴ پارامتر آزمایشی است. عملکرد این مدل همراه با دقت ۷۶ درصد است [۲۱].

هدف این مطالعه استفاده از روش‌های هوش مصنوعی و پیرو آن یادگیری عمیق برای پیش‌بینی بیماری‌های مربوط به قلب است که از آریتمی قلب حاصل می‌شوند تا پزشکان و مراکز بهداشتی و درمانی بتوانند با استفاده از آن‌ها به راهکارهایی برای تشخیص زودهنگام بیماری دست یابند. درواقع، برخلاف دستگاه‌های پزشکی مانند مانیتور قلب که علائم حیاتی فرد را مورد بررسی قرار می‌دهد، هوش مصنوعی می‌تواند اطلاعات این دستگاه را جمع‌آوری کرده و پس از تجزیه و تحلیل متوجه شرایط پیچیده‌تری مانند خطراتی که بیمار را در آینده تهدید می‌کند، شود. مدل پیشنهادی در این پژوهش جهت پیش‌بینی بیماری قلبی از روی سیگنال‌های ECG می‌باشد. مدل پیشنهادی با توجه به فیلترهایی که روی ماتریس ورودی اعمال می‌کند، توانایی استخراج ویژگی‌های سطح میانی را دارند. به همین دلیل یادگیری دقیق تری را ارائه خواهد داد. همچنین با انتخاب ویژگی‌های مؤثرتر سرعت یادگیری نیز افزایش پیدا خواهد کرد.

روش کار

با توجه به بررسی‌های انجام شده معرفی مدلی هوشمند برای پیش‌بینی زودهنگام بیماری قلبی ضروری به نظر می‌رسد تا جهت افزایش دقت پیش‌بینی، مدلی مبتنی بر ترکیب شبکه‌های یادگیری عمیق ارائه شود. بدین منظور با اعمال الگوریتم‌های مختلف یادگیری عمیق بر روی پایگاه داده تعیین شد و انجام طبقه‌بندی به بررسی عملکرد شبکه‌های عصبی عمیق برای تشخیص بیماری‌های قلبی پرداخته شد و با یافتن پارامترهای مناسب برای آموزش شبکه‌های عصبی عمیق و سپس ارزیابی و با بررسی کارایی مدل‌های مختلف، مدل بهینه پیشنهاد

گردید. هدف از این مطالعه، افزایش دقت پیش‌بینی تک تک طبقات است تا بتوان دقت کل تشخیص بیماران قلبی را بهبود داد. شکل ۱، روند کلی روش پیشنهادی را نشان می‌دهد.



شکل ۱: مدل پیشنهادی جهت بهبود دقت شناسایی طبقات آریتمی قلب

در مدل پیشنهادی و با توجه به شکل ۱، ابتدا نمونه‌ها بر اساس کلاس به مجموعه‌های مشخص تفکیک شدند. سپس به وسیله الگوریتم‌های وزن‌دهی، به ویژگی‌ها وزن‌دهی شدند. در ادامه تعیین مقدار آستانه و اعتبارسنجی با تابع هدف درخت تصمیم توسط الگوریتم بهینه‌سازی ذرات انجام شد که در پایان، روند کلی این الگوریتم تکاملی منجر به استخراج ویژگی‌های مؤثر گردید. با توجه به ارزیابی الگوریتم‌ها مشخص شد که الگوریتم یادگیری عمیق بر روی این مجموعه داده کارایی بالایی دارد؛ لذا فرآیند اعتبارسنجی ده مرحله‌ای K-Fold با الگوریتم یادگیری عمیق پیچشی انجام پذیرفت. در پایان انتظار می‌رود ویژگی‌های مؤثر شناخته شده و دقت کل طبقه‌بندی بهبود یابد. علاوه بر دقت کل طبقه‌بندی، دقت و جامعیت هر طبقه گزارش شد. در ادامه جزئیات مدل پیشنهادی توضیح داده می‌شود:

- **بهینه‌سازی ازدحام ذرات:** در الگوریتم بهینه‌سازی ازدحام ذرات با توجه به فضا و نقاطی که در این فضا وجود دارد، یکسری نقاط بهینه وجود دارد که نقاط دیگر به سمت نقاط بهینه حرکت می‌کنند. این فرآیند شبیه حرکت پرندگان در یک گروه می‌باشد. منظور از نقاط همان ترکیب ویژگی‌های مختلف است و نقطه بهینه همان تعداد ویژگی‌های پایین و دقت بالا می‌باشد. نقاط با دقت کم سعی می‌کنند خود را به نقاط بهینه نزدیک کنند؛ یعنی می‌خواهند خود را شبیه به نقطه بهینه کنند؛ بنابراین ویژگی‌هایشان را شبیه نقطه بهینه می‌کنند. در نهایت این الگوریتم مشخص می‌کند که کدام ترکیب از ویژگی‌ها (کروموزوم) بالاترین دقت را دارا است. به ویژگی‌های موجود در کروموزوم وزن می‌دهد. در این جا از الگوریتم درخت تصمیم به عنوان تابع هدف یا برازش استفاده می‌شود، یعنی کروموزوم‌های ایجاد شده به این الگوریتم ارسال می‌شوند و الگوریتم تعیین می‌کند که دقت هر کروموزوم چقدر است.



• **شبکه‌های عصبی کانولوشن CNN:** شبکه عصبی کانولوشن یا پیچشی، نوعی شبکه عصبی مصنوعی است که از عملکرد قشر بینایی انسان‌ها و حیوانات الهام گرفته شده است و برای کاربردهایی مانند بازشناسی تصویر و ویدئو، بازشناسی گفتار، سیستم‌های توصیه‌گر، پردازش زبان‌های طبیعی و سایر موارد مورد استفاده قرار می‌گیرد. فرض اصلی در معماری CNN این است که عملیات بر روی داده‌های ورودی انجام می‌شود تا اطلاعات مکانی و همسایگی در اطلاعات حفظ شوند و در نهایت یک بردار از ویژگی‌های کدگذاری شده به دست می‌آید. به‌طور کلی، یک شبکه CNN از سه لایه اصلی تشکیل می‌شود که عبارت‌اند از: لایه کانولوشن، لایه ادغام و لایه تماماً متصل. لایه‌های مختلف وظایف مختلفی را انجام می‌دهند. در هر CNN دو مرحله برای آموزش وجود دارد. مرحله جلو رونده و مرحله پس انتشار خطا. در طول فرآیند آموزش، وزن‌های مشترک در لایه‌های کانولوشن و همچنین وزن‌های موجود میان لایه‌های کاملاً متصل کانولوشن، به‌طور قابل توجهی سبب کاهش تعداد پارامترهای آزاد آموزش‌پذیر شبکه و در نتیجه افزایش تعمیم‌پذیری می‌شود [۲۲]. CNN استفاده شده در این تحقیق به‌طور کلی از لایه‌های زیر تشکیل شده است:

- **لایه کانولوشن:** این لایه هسته اصلی تشکیل دهنده CNN است. پارامترهای لایه کانولوشن شامل مجموعه‌ای از فیلترهای قابل یادگیری هستند. در این لایه‌ها، شبکه عصبی کانولوشن از فیلترهای مختلف برای در هم پیچش (کانوال) داده‌های ورودی و همین‌طور نگاشت ویژگی‌های میانی استفاده می‌کند. این‌گونه نگاشت ویژگی‌های مختلف در انجام عملیات کانولوشن چند مزیت اصلی دارد: اول این که مکانیزم اشتراک وزن در هر نگاشت ویژگی، باعث کاهش شدید تعداد پارامترها می‌شود و اتصال محلی، ارتباط بین پیکسل‌های همسایه را یاد می‌گیرد. دومین مزیت این است که باعث تغییر ناپذیری و ثبات نسبت به تغییر مکان شیء می‌شود و نسبت درجه آزادی سیستم و تعداد نمونه‌های لازم برای یادگیری، به‌طور محسوسی افزایش می‌یابد و این امر باعث می‌شود تا قدرت تعمیم سیستم قوی‌تر شود. همان‌طور که اشاره شد این لایه عمل کانولوشن را روی سیگنال EEG ورودی با استفاده از کرنل انجام می‌دهد.

رابطه ۱، معادله لایه ReLU است که این لایه روش غیرخطی را به شبکه معرفی می‌کند که رایج‌ترین تابع فعال‌ساز می‌باشد:

$$x = \max(0, x) \quad \bullet \quad (1)$$

- **لایه‌های ادغام:** یک لایه ادغام معمولاً بعد از یک لایه کانولوشنی قرار می‌گیرد و از آن برای کاهش اندازه نگاشت ویژگی‌ها و پارامترهای شبکه می‌توان استفاده کرد. همانند لایه‌های کانولوشنی، لایه‌های ادغام به خاطر در نظر گرفتن پیکسل‌های همسایه در محاسبات خود، نسبت به تغییر مکان بی‌تغییر هستند. پیاده‌سازی لایه ادغام با استفاده از تابع ماکزیمم و میانگین رایج‌ترین پیاده‌سازی‌ها صورت می‌گیرد.

- **لایه تماماً متصل:** بعد از آخرین لایه ادغام، لایه‌های تماماً متصل وجود دارند. این لایه‌ها اجازه می‌دهند تا نتیجه شبکه در قالب یک بردار با اندازه مشخص نشان داده شود. می‌توان از این بردار جهت ادامه پردازش‌های بعدی بهره برد.

- **لایه حذف تصادفی:** از این لایه به‌منظور جلوگیری از پدیده بیش‌برازش استفاده می‌شود. نحوه کار آن به این صورت است که در هر مرحله از آموزش، هر نورون با احتمالی از شبکه بیرون انداخته می‌شود.

- **فرا پارامترها:** تکنیک بیرون انداختن به منظور جلوگیری از بیش پوشش معرفی می‌شود و نحوه کار آن به این صورت است که در هر مرحله از آموزش، هر نورون یا با احتمال $p-1$ (از شبکه) بیرون انداخته شده و یا با احتمال p نگه داشته می‌شود به طوری که نهایتاً یک شبکه کاهش داده شده باقی بماند. سه فراپارامتر اندازه توده خروجی را کنترل می‌کنند. این سه پارامتر عمق، گام و لایه گذاری با صفر هستند. پارامتر عمق، تعداد نورون‌هایی که در لایه کانولوشن به یک ناحیه در توده ورودی متصل می‌شوند را کنترل می‌کند.

- **تابع فعال‌سازی:** پس از هر لایه کانولوشن، یک تابع فعال‌سازی اعمال می‌شود. تابع فعال‌سازی یک عملگر است که خروجی را به مجموعه‌ای از ورودی‌ها نگاشت می‌کند و برای غیرخطی کردن ساختار شبکه استفاده می‌شود. در این پژوهش از ReLU به عنوان



فعال‌سازی در لایه‌های کانولوشن استفاده شده است و از آنجایی که خاصیت غیرخطی بودن را دارا است، در برابر تغییرات جزئی نسبت به ورودی مقاوم است.

-**تابع سافت مکس:** این تابع توزیع احتمالی کلاس‌های خروجی را محاسبه می‌کند و در لایه تمام متصل آخر برای پیش‌بینی تشخیص بیماران قلبی استفاده می‌شود.

نتایج

کلیدیه قسمت‌های این مطالعه توسط نرم افزار پایتون شبیه‌سازی شده است. مجموعه داده به دو زیرمجموعه‌های آموزش و آزمون تقسیم شدند. در ادامه دیتاست و فازهای اصلی پیاده سازی مدل پیشنهادی شرح داده می‌شود.

• دیتاست (UCI (<https://www.kaggle.com/datasets/redwankarimsony/heart-disease-data>))


در این مطالعه، به منظور پیش‌بینی وجود یا عدم وجود آریتمی‌های قلبی از مخزن یادگیری ماشین UCI استفاده شده است. داده‌ها شامل ۴۵۲ رکورد با تعداد ۲۷۹ ویژگی برای هر رکورد ارائه شده‌اند. جدول ۱ توضیحات کامل این دیتاست را نمایش می‌دهد.

جدول ۱: برچسب‌های کلاس و درصد داده‌های تکراری در مجموعه داده UCI

ردیف	برچسب کلاس (انگلیسی)	برچسب کلاس (فارسی)	درصد تکرار
۱	Normal	عادی	۵۴/۲
۲	Coronary Artery Disease	بیماری عروق کرونر	۹/۷
۳	Old Anterior Myocardial Infarction	انفارکتوس قلبی (قدامی)	۳/۳
۴	Old Inferior Myocardial Infarction	انفارکتوس قلبی (میوکارد)	۳/۳
۵	Sinus Tachycardia	تندتپشی سینوسی	۲/۹
۶	Sinus Bradycardia	کندتپشی سینوسی	۵/۵
۷	Ventricular Premature Contraction	انقباضات زودرس بطنی	۰/۷
۸	Supraventricular Premature Contraction	انقباض زودرس فوق بطنی	۰/۴
۹	Left Bundle Branch Block	انسداد شاخه‌ای رشته چپ	۲
۱۰	Right Bundle Branch Block	انسداد شاخه‌ای رشته راست	۱۱/۱
۱۱	1 ST Degree AV Block	اولین مرحله انسداد قلبی	۰
۱۲	2 ST Degree AV Block	دومین مرحله انسداد قلبی	۰
۱۳	3 ST Degree AV Block	سومین مرحله انسداد قلبی	۰
۱۴	Left Vertical Hypertrophy	هیپرتروفی بطن چپ	۰/۹
۱۵	Atrial Fibrillation	آریتمی فیبریلاسیون دهلیزی	۱/۱
۱۶	Others	سایر	۴/۹

رکوردها با تخصیص یک برچسب از ۱۶ کلاس مختلف، برچسب‌گذاری می‌شوند. برچسب کلاس ۱، نشان دهنده عدم وجود بیماری است و ۱۵ کلاس دیگر انواع مختلف آریتمی را مشخص می‌کنند. با توجه به این که ۱۶ کلاس در مجموعه دادگان تعریف شده است نیاز است در قدم اول توزیع داده‌ها در هر کلاس مشاهده شود. همان‌طور که در شکل ۲ قابل مشاهده است، بیش از ۷۰ درصد از داده‌ها در وضعیت نرمال هستند. اساساً برخی از کلاس‌ها مانند کلاس‌های ۷، ۸، ۱۱ و ۱۲ که کمتر از ۳ درصد داده‌های مجموعه دادگان را در اختیار دارند شرایط عادی برای آموزش پذیری ندارند. به عنوان مثال کلاس ۸ تنها دو نمونه در بر دارد که بدان معنی است آموزش‌پذیری با یک نمونه و آزمون با نمونه دیگر صورت می‌پذیرد که شرایط آموزش‌پذیری آن قابل قبول نخواهد بود.

لازم است توضیح داده شود که در این مطالعه آموزش و آزمون و اعتبارسنجی با استفاده از K-fold cross validation، انجام شد به طوری که ($K=10$) می باشد. در این نوع آموزش، دیتاست به k شکل مختلف تقسیم می شود. مدل k بار روی این k fold آموزش داده می شود. به این صورت k دقت به دست آمده و در نهایت میانگین این دقت ها محاسبه می شود.



شکل ۲: توزیع نمونه ها در کلاس های مجموعه دادگان آریمی قلب

• جایگزینی مقادیر از دست رفته در روش پیشنهادی


درک مفهوم مقادیر از دست رفته برای مدیریت موفق داده ها مهم است. اگر مقادیر از دست رفته توسط محقق به درستی مدیریت نشود، ممکن است در نهایت نتیجه گیری نادرست درباره داده ها صورت بگیرد. با توجه به مدیریت نادرست، در جایی که مقادیر از دست رفته وجود دارد، نتیجه به دست آمده توسط پژوهشگر از نتایج دیگران متفاوت خواهد بود. موارد بدون پاسخ زمانی رخ می دهد که پاسخ دهنده به سؤالات خاص به دلیل استرس، خستگی یا کمبود دانش پاسخ نمی دهد. پاسخ دهندگان ممکن است به برخی سؤالات به دلیل حساسیت پاسخ ندهند که این فقدان پاسخ، مقادیر از دست رفته را شامل می شوند. محقق ممکن است به جای داده های از دست رفته از حذف یا جایگزینی داده ها استفاده کند. اگر تعداد موارد از دست رفته کمتر از ۵٪ از موارد باشد، محقق می تواند این مقادیر را از تجزیه و تحلیل حذف کند.

• فاز اول: پیش پردازش داده ها

اولین گام خواندن مجموعه دادگان ورودی می باشد. سپس به یک ستون از مجموعه دادگان که نوع نارسایی های قلبی را مشخص می کند، نقش برچسب داده می شود. در مرحله بعد گسسته سازی انجام می شود یعنی هر مقدار عددی از ستون متغیر کلاس به مقدار اسمی از بیماری قلبی تبدیل می شود (به عنوان مثال مقدار ۴ به مقدار اسمی آنفراکتوس میوکارد درجه دوم که به اختصار با (Inferior Myocardial Infarction) IMI نشان داده می شود، تبدیل شده است). از آنجا که در بعضی از فیله های مجموعه دادگان، داده های از دست رفته وجود دارد و این داده ها با علامت سؤال پر می شوند، در مرحله بعد تعیین می شود که به جای این علامت های سؤال در مجموعه دادگان از فضای خالی استفاده شود. بعد از جایگزینی فضاهای خالی به جای علامت سؤال تمام اعدادی که از نوع عددی نیستند به نوع عددی تبدیل می شود و داده های از دست رفته توسط جایگزینی مقادیر از دست رفته به روش میانگین گیری ستونی پر می شوند. بعد از تغییرات مذکور، مجموعه داده تغییر یافته در فایل جدیدی ذخیره می شود. این عملیات، داده ها را آماده می کند تا فرآیندهای انتخاب ویژگی و طبقه بندی، درست انجام شوند.


• فاز دوم: طبقه بندی با استفاده از الگوریتم های رایج یادگیری ماشین

در این فاز مانند فاز قبل مجموعه دادگان تولید شده در فاز قبل خوانده می‌شوند و داده‌ها بدون بررسی و در نظر گرفتن داده‌های از دست رفته به سه طبقه‌بند درخت تصمیم، k نزدیک‌ترین همسایه، بیز ساده و CNN ارسال می‌شوند. هدف از استفاده از الگوریتم‌های مختلف این است که عملکرد این الگوریتم‌ها با یکدیگر مقایسه شوند تا مشخص شود که کدام الگوریتم عملکرد بهتری دارد. شکل ۳، دقت به دست آمده توسط الگوریتم‌های درخت تصمیم، k نزدیک‌ترین همسایه، بیز ساده و CNN بدون تغییری بر روی داده‌های از دست رفته را نشان می‌دهد.



شکل ۳: دقت به دست آمده توسط الگوریتم‌های درخت تصمیم، k نزدیکترین همسایه، بیز ساده و CNN بدون تغییری بر روی داده‌های از دست رفته

همچنین تمامی آزمایش‌ها با توجه به انجام عملیات و اصلاحات بر روی داده‌های از دست رفته، مجدداً بر روی طبقه‌بندهای درخت تصمیم، k نزدیک‌ترین همسایه، بیز ساده و CNN اعمال شده‌اند. شکل ۴، دقت عملکرد این الگوریتم‌ها را نشان می‌دهد.




شکل ۴: دقت به دست آمده توسط الگوریتم‌های درخت تصمیم، k نزدیکترین همسایه، بیز ساده و CNN با اصلاحات بر روی داده‌های از دست رفته

با بررسی شکل ۴، مشاهده می‌شود که دقت به دست آمده توسط الگوریتم‌های درخت تصمیم، k نزدیک‌ترین همسایه، بیز ساده و CNN با مقادیر از دست رفته به ترتیب برابر است با ۵۵/۶۱، ۵۴/۸۸، ۱۴/۶۱ و ۵۵/۹۷ درصد است. با مقایسه دقت‌های به دست آمده

در جداول ۳ و ۴ نتایج نشان داد که دقت به دست آمده در طبقه‌بندی‌های اشاره شده در متن با داده‌های از دست رفته نتایج بهتری را ارائه می‌دهند. همچنین عملکرد CNN نسبت به سایر روش‌ها بالاتر می‌باشد.

• فاز سوم: انتخاب ویژگی با استفاده از الگوریتم‌های PSO، ژنتیک و پراکندگی اطلاعات

در این فاز به منظور انتخاب ویژگی از سه روش مختلف بهینه‌سازی ازدحام ذرات (PSO(Particle swarm optimization)، الگوریتم ژنتیک (GA(Genetic Algorithm) و پراکندگی اطلاعات (IG(Information Gain) استفاده شده است. انتخاب ویژگی به این دلیل انجام می‌شود تا از میان ویژگی‌های مجموعه دادگان، آن‌هایی که اهمیت بیشتری دارند، انتخاب شوند و تعداد ویژگی‌ها کاهش یابد. اگر این کار به خوبی انجام شود، باعث می‌شود که زمان پاسخ و پیچیدگی، کمتر شده و همچنین سرعت پردازش و دقت به دست آمده، بیشتر شود؛ بنابراین این مرحله، بسیار مهم است. شکل ۵ دقت به دست آمده جهت انتخاب ویژگی توسط الگوریتم‌های بهینه‌سازی ازدحام ذرات، الگوریتم ژنتیک و پراکندگی اطلاعات را نشان می‌دهد. در مجموعه دادگان این مطالعه، الگوریتم بهینه‌سازی ازدحام ذرات نسبت به دو الگوریتم دیگر در انتخاب ویژگی، عملکرد بهتری داشته است. بعد از فرآیند انتخاب ویژگی، طبقه‌بندی توسط الگوریتم یادگیری عمیق انجام شد.



شکل ۵: دقت‌های به دست آمده پس از انتخاب ویژگی توسط الگوریتم‌های بهینه‌سازی ازدحام ذرات، الگوریتم ژنتیک و پراکندگی اطلاعات

• فاز چهارم: روش پیشنهادی

از آنجایی که اجرای برنامه بر پایه یادگیری عمیق صورت گرفته و به جهت محاسبات و پردازش اطلاعات از میان میلیون‌ها داده مختلف انجام می‌گیرد، از یک پردازنده معمولی نمی‌توان انتظار داشت این عملیات را انجام دهد؛ لذا ضرورت تهیه سخت‌افزارهایی با سرعت بالاتر و قوی‌تر از نیازهای مهم فرآیند فوق می‌باشد. برای پیاده‌سازی روش پیشنهادی از زبان برنامه‌نویسی پایتون استفاده شده است که باعث تسهیل طراحی و پیاده‌سازی الگوریتم‌های یادگیری ماشین و یادگیری عمیق شده است. برای استفاده از محیط برنامه‌نویسی پایتون، از آناکوندا (Anaconda) استفاده شده است. به طور خلاصه، کلیه پیاده‌سازی‌های این مطالعه به کمک پایتون ۳ و کتابخانه تنسورفلو (Tensor Flow) ۰.۱.۲ روی سیستم با پردازنده Intel Xeon 2 E5-2620 2.0 GH و ۸ گیگابایت رم در محیط لینوکس (Linux) انجام شده است. هایپیرامترهای مورد استفاده برای تنظیم مدل پیشنهادی در جدول ۲ نشان داده شده است.

جدول ۲: هایپر پارامترهای مورد استفاده برای تنظیم مدل پیشنهادی

۰/۰۰۱	نرخ یادگیری
۵۰۰	تکرار
Adam	بهینه‌ساز
۲	سایز دسته
ReLU	تابع فعال‌ساز
۱۲	زیرمجموعه
۰/۰۰۰۵	کاهش وزن

در این فاز ابتدا مجموعه دادگان خوانده می‌شوند و به دو دسته داده‌ها با مقادیر معتبر و داده‌ها با مقادیر از دست رفته تقسیم می‌شوند. به تمامی مقادیر معتبر برچسب الحاق می‌شود و برای مقداردهی مقادیر از دست رفته، از روش جایگزینی مقادیر به روش میانگین گیری ستونی استفاده شد. در ادامه به منظور انتخاب ویژگی، الگوریتم بهینه‌سازی ازدحام ذرات اعمال می‌شود. به طوری که ۲/۳ از ویژگی‌های مفید انتخاب می‌شود.

عملیات انتخاب ویژگی برای هر کدام از مجموعه‌ها انجام می‌شود تا مشخص شود کدام ویژگی‌ها در هر مجموعه داده ادغام گردند. به منظور ادغام ویژگی‌ها از الگوریتم درخت تصمیم استفاده شد. یعنی الگوریتم درخت تصمیم به عنوان تابع هدف یا برازش در الگوریتم تکاملی بهینه‌سازی ازدحام ذرات مورد استفاده قرار می‌گیرد.

در مرحله انتخاب ویژگی که توسط الگوریتم بهینه‌سازی ازدحام ذرات صورت گرفت، به ویژگی‌های منتخب وزن داده می‌شود. همچنین نیاز است که توسط الگوریتمی مقدار آستانه وزنی تعیین شود تا وزن‌های بالاتر از حد آستانه باقی بمانند و بقیه حذف شوند؛ بنابراین برای هر کدام از مجموعه‌ها، آستانه وزن تعیین می‌شود.

در توضیحات اضافی می‌توان گفت در بهینه‌سازی ذرات (Particle Swarm Optimization) هر ذره به عنوان یک نقطه در فضای جستجوی d بعدی در نظر گرفته می‌شود. هر ذره یا راه حل کاندید می‌تواند بهترین راه حل خود را در فضای جستجو و بهترین تجربیات خود را در میان کل گروه به خاطر بسپارد. اساساً، در PSO از یک بردار $[x_{i1}, x_{i2}, \dots, x_{iD}]$ به عنوان نمایش موقعیت ذرات i استفاده می‌شود و D ابعاد فضای جستجو است. علاوه بر این، سرعت ذره i به عنوان بردار $[v_{i1}, v_{i2}, \dots, v_{iD}]$ نشان داده می‌شود. بهترین موقعیتی که توسط ذرات ایجاد می‌شود، به عنوان p_{best} از موقعیت‌های تعریف شده ایجاد می‌شود و بهترین موقعیت عمومی نیز به عنوان g_{best} در نظر گرفته می‌شود. تغییرات ازدحام براساس موقعیت خود توسط (۱) و سرعت را بر اساس (۲) محاسبه می‌گردد.

$$x_{id}^{(t+1)} = x_{id}^{(t)} + v_{id}^{(t+1)} \quad (1)$$

$$v_{id}^{(t+1)} = w * v_{id}^{(t)} + c_1 r_1 (p_{id} - x_{id}^{(t)}) + c_2 r_2 (p_{gd} - x_{id}^{(t)}) \quad (2)$$



در جایی که تعداد تکرارها در فرآیند جستجو با t نشان داده می‌شود، بعد فضای جستجو با d و ثابت‌های شتاب با C_1, C_2 نشان داده می‌شوند. مقادیر تصادفی Γ_1 و Γ_2 به طور یکنواخت بین $[0, 1]$ توزیع می‌شوند. بهترین راه‌حل‌های p_{best} و g_{best} به صورت p^{id} و p_{gd} نمایش داده می‌شوند و وزن اینرسی با W نشان داده می‌شود. در این جا، دقت طبقه‌بندی درخت تصمیم به عنوان یک ارزیاب عملکرد در تعدادی از ویژگی‌ها در ساخت تابع تناسب استفاده شده است؛ بنابراین تعداد ویژگی‌های زیرمجموعه و دقت طبقه‌بندی کننده در تابع تناسب (۳) در نظر گرفته شده است.

$$f(x) = \alpha(1 - P) + (1 - \alpha)\left(1 - \frac{N_t - N_f}{N_t}\right) \quad (3)$$

جایی که اندازه کل ویژگی‌ها به صورت (N_t) ، اندازه زیرمجموعه ویژگی‌ها به صورت (N_f) ، اندازه گیری عملکرد طبقه بندی کننده با (P) نشان داده می‌شود، و α عددی ثابت بین $\{0, 1\}$ است.

باقی پارامترهای الگوریتم پیشنهادی در جدول ۳ و به شرح ذیل آمده است:

جدول ۳: پارامترها و مقادیر

مقدار	پارامترها
۷۶	اندازه جمعیت
۱۰۰	تعداد تکرار
۰/۹۹	α در تابع برازش
$C_2=2, C_1=2$	C_1, C_2
۰/۳	وزن میانی
۲	درجه اتصالات (p)

با توجه مجموعه دادگان، تمام ۱۶ طبقه از انواع بیماری‌های قلبی با یکدیگر ترکیب می‌شوند. از آنجا که بعد از فرآیندهای ذکر شده ویژگی‌های مختلفی از هر طبقه انتخاب شده است، با ادغام آن‌ها داده‌های از دست رفته به وجود می‌آیند. سپس تمامی ویژگی‌های انتخاب شده به طبقه‌بندهای درخت تصمیم، k نزدیک‌ترین همسایه، بیز ساده و CNN ارسال می‌شوند. جدول ۳، نتایج دقت دسته‌بندی با استفاده از روش‌های مختلف یادگیری‌های ماشین و یادگیری‌های عمیق، جهت تشخیص بیماران قلبی را نشان می‌دهد. تمامی این آزمایش‌ها یک بار بدون در نظر گرفتن استخراج‌گر ویژگی‌ها و بار دیگر با در نظر گرفتن استخراج‌گر ویژگی‌ها انجام شده است.

جدول ۴: مقایسه‌ای از دقت کلی به دست آمده از الگوریتم‌های مختلف قبل و بعد از اعمال روش پیشنهادی

دقت طرح پیشنهادی	دقت با طبقه‌بند ساده	الگوریتم‌ها
۹۱/۸۹	۵۴/۲۲	درخت تصمیم
۸۸/۱۱	۵۳/۵۴	k نزدیک‌ترین همسایه
۹۰/۹۹	۱۴/۵۹	بیز ساده
۹۲/۳۴	۸۵/۲۲	CNN
۹۰/۰۱	۸۱/۹۹	AlexNet
۹۰/۲۰	۸۲/۰۱	VGGNet
۹۱/۳۳	۸۳/۰۰	ResNet

نتایج نشان داد که الگوریتم‌های یادگیری عمیق نتایج بهتری را نسبت به یادگیری ماشین ارائه داده‌اند. همچنین مدل پیشنهادی نسبت به سایر روش‌ها جواب بهتری را در خروجی داشته است (جدول ۴).

جدول ۵: نتایج مقالات مختلف و مقایسه با روش پیشنهادی روی دیتاست UCI

نتایج	سال انتشار	مدل پیشنهادی	شماره مرجع
ANFIS, ANN-LM, ANN-BFG, دقت= ۹۴/۷٪، ۹۶/۲٪، ۹۱/۵۰٪	۲۰۲۳	SVR, ANFIS, M5 Tree	[۲۳]
XGB دقت=۹۰٪ بازیابی=۱۰۰٪ معیار F=۹۵٪ دقت=۹۱/۸٪	۲۰۲۲	AB, LR, CART, SVM, LDA, RF, XGB	[۲۴]
صحت=۸۶٪ بازیابی=۸۱٪ معیار F=۸۴٪ دقت=۸۶٪	۲۰۲۱	CNN	[۲۵]
صحت=۹۳/۲۲٪ بازیابی=۹۰/۶۷٪ معیار F=۹۴/۴۸٪ دقت=۹۲/۳۴٪	-	CNN+PSO	مدل پیشنهادی

جدول ۵، نتایج ارائه شده در پژوهش‌های مختلف را با استفاده از معیارهای ارزیابی مختلف و روی دیتاست UCI نشان می‌دهد. همچنین نتایج روش پیشنهادی با استفاده از معیارهای ارزیابی Recall، Precision، F1-score و Accuracy در جدول ۵ نشان داده شده است. با بررسی نتایج نشان داد که مدل پیشنهادی نسبت به سایر روش‌های مختلف نتایج بهتری را ارائه داده است.

بحث و نتیجه‌گیری

استفاده از داده‌کاوی در پزشکی، دانشی است که با بهره‌مندی از ابزارهای نوین داده‌کاوی، به پزشکان در تشخیص و پیش‌بینی زود هنگام بیماری‌ها کمک قابل توجهی نموده است. درحالی‌که داده‌کاوی اطلاعات مفیدی را فراهم می‌کند و کارکنان گروه درمانی را در شناسایی الگوهای پنهان یاری می‌دهد، محدودیت‌هایی نیز دارد که داده‌کاوی قادر به انجام آن‌ها نیست. همه الگوهای یافت شده از این طریق درست و دقیق نیستند و برای استفاده از یک الگو و اطمینان به آن، الگوی مورد نظر باید منطقی و در عمل قابل اجرا باشد. به همین دلیل در این مطالعه از مدلی استفاده شده تا کارایی لازم را جهت تشخیص زود هنگام بیماران قلبی داشته باشد. به طور خلاصه سلسله روال مدل پیشنهادی به این صورت است که در فاز اول مجموعه داده‌ها را پردازش می‌شوند. سپس عملیات گسسته‌سازی و جایگزینی مقادیر از دست رفته به روش میانگین‌گیری ستونی روی داده‌های ورودی در مرحله پیش‌پردازش انجام می‌شود. سپس به منظور کاهش ویژگی‌ها، پیچیدگی و افزایش سرعت و دقت، عملیات انتخاب ویژگی روی داده‌های نرمال شده صورت گرفته و به طبقه‌بندی‌های درخت تصمیم، k نزدیک‌ترین همسایه، بیز ساده، CNN، AlexNet، VGGNet و ResNet ارسال می‌شوند. نتایج نشان داد که دقت CNN نسبت به سایر طبقه‌بندها دقت بالاتری را دارد.

براساس نتایج حاصل از آزمایش‌ها، مدل پیشنهادی از دقت بالاتری نسبت به سایر روش‌های انجام شده از یادگیری‌های ماشین و یادگیری‌های عمیق معرفی شده در این مطالعه برخوردار است.



همچنین از معیارهای ارزیابی *Accuracy* و *Fl-score*، *Recall*، *Precision* جهت بررسی کارایی مدل پیشنهادی استفاده شده و نتایج آن با سایر روش‌های رقیب مقایسه شده است و نتایج نشان داد که مدل پیشنهادی از دقت بالاتری نسبت به سایر روش‌های مقایسه شده در متن، برخوردار است.

لازم به ذکر است در شرایطی که بتوان مدل‌های یادگیری عمیق را با حجم عظیمی از داده‌ها آموزش داد، این مدل‌ها از کارایی خوبی برخوردار خواهند بود؛ اما همواره در کاربردهای مختلف مجموعه داده به اندازه کافی بزرگ، که بتوان این مدل‌ها را با آن آموزش داد، وجود ندارد. به همین دلیل پیشنهاد می‌گردد از روش‌های انطباق دامنه و انتقال یادگیری در این کاربرد استفاده شود. به این ترتیب می‌توان از دانش به‌دست آمده از سایر مجموعه داده‌های موجود، که ممکن است دامنه متفاوتی با کاربرد مورد نظر داشته باشند، در یادگیری مدل‌ها استفاده کرد.

در سطح مدل یادگیری و در همین مدل پیشنهادی نیز می‌توان تعداد لایه‌های شبکه را افزایش داد و میزان تأثیر آن را مشاهده نمود. همچنین با توجه به این که هر کدام از مدل‌های یادگیری عمیق دارای مزایا و معایب خود هستند، می‌توان مدل‌های مختلف یادگیری عمیق را با هم ترکیب کرد تا در تشخیص زودهنگام بیماران قلبی در مراکز مختلف بیمارستان‌ها، درمانگاه‌ها و کلینیک‌های خصوصی از این روش‌ها استفاده کرد.

تعارض منافع

هیچ گونه تضاد منافی بین نویسندگان وجود ندارد.

سهام مشارکت نویسندگان

مفهوم و طراحی روش، تجزیه و تحلیل و تفسیر داده‌ها: سارا معتمد، پیش نویس مقاله، تجزیه و تحلیل آماری و بازبینی مقاله توسط الهام عسکری انجام شده است.

References

- [1]. Ahsan MM, Siddique Z. Machine learning-based heart disease diagnosis: A systematic literature review. *Artificial Intelligence in Medicine* 2022;128:102289. <https://doi.org/10.1016/j.artmed.2022.102289>
- [2]. Brites IS, da Silva LM, Barbosa JL, Rigo SJ, Correia SD, Leithardt VR. Machine learning and iot applied to cardiovascular diseases identification through heart sounds: A literature review. *Informatics* 2021; 8(4): 73. <https://doi.org/10.3390/informatics8040073>
- [3]. Diwakar M, Tripathi A, Joshi K, Memoria M, Singh P. Latest trends on heart disease prediction using machine learning and image fusion. *Materials Today: Proceedings* 2021;37:3213-8. <https://doi.org/10.1016/j.matpr.2020.09.078>
- [4]. Elhoseny M, Mohammed MA, Mostafa SA, Abdulkareem KH, Maashi MS, Garcia-Zapirain B, et al. A New Multi-Agent Feature Wrapper Machine Learning Approach for Heart Disease Diagnosis. *Computers, Materials & Continua* 2021;67(1): 51-71. doi: 10.32604/cmc.2021.012632
- [5]. Elias P, Poterucha TJ, Rajaram V, Moller LM, Rodriguez V, Bhave S, et al. Deep learning electrocardiographic analysis for detection of left-sided valvular heart disease. *Journal of the American College of Cardiology* 2022;80(6):613-26.
- [6]. Kavitha M, Ganeswar G, Dinesh R, Sai YR, Suraj RS. Heart disease prediction using hybrid machine learning model. 6th International Conference on Inventive Computation Technologies (ICICT); 2021 Jan 20; p. 1329-33. Coimbatore, India: IEEE; 2021. doi: 10.1109/ICICT50816.2021.9358597
- [7]. Fereidooni M, Estakhrian AM. Design and simulation of bioelectrical system that can be trained in the diagnosis of heart arrhythmia diseases using neural network. The First National Conference on Electrical Engineering of The Young and Elite Researchers Club; 2016 Apr 26; Shiraz: Islamic Azad University of Shiraz; 2016. [In Persian]
- [8]. Naruei I, Zamani B. Diagnosis of Cardiac Arrhythmia Using Pca and MLP Neural Network. The Second Conference on New Research in Science and Technology; 2015 Jul 20; Kerman: Elm Mehvaran Asman Company; 2018. [In Persian]

- [9]. Dashti nejad N, Askar Farashah M. Diagnosis of liver and heart disease through iridology based on error backpropagation network. 2015 Sep 5; International Conference on New Research Findings in Electrical Engineering and Computer Science, Tehran: Nikan; 2016. [In Persian]
- [10]. Palaniappan S, Awang R. Intelligent heart disease prediction system using data mining techniques. In 2008 IEEE/ACS International Conference on Computer Systems and Applications; 2008 Mar-Apr 31-4; Doha, Qatar: IEEE; 2008. p. 108-15. doi: 10.1109/AICCSA.2008.4493524.
- [11]. Venkatalakshmi B, Shivsankar MV. Heart disease diagnosis using predictive data mining. International Journal of Innovative Research in Science, Engineering and Technology 2014;3(3):1873-7.
- [12]. Masethe HD, Masethe MA. Prediction of heart disease using classification algorithms, Proceedings of the World Congress on Engineering and Computer Science. USA, 2014. doi: https://www.iaeng.org/publication/WCECS2014/WCECS2014_pp809-812.pdf.
- [13]. Mustaqeem A, Anwar SM, Majid M, Khan AR. Wrapper method for feature selection to classify cardiac arrhythmia. In 2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) 2017 Jul 11; Jeju, Korea (South): IEEE; 2017. p. 3656-59. doi: 10.1109/EMBC.2017.8037650
- [14]. Zhang Y, Zhou ZH. Multilabel dimensionality reduction via dependence maximization. ACM Transactions on Knowledge Discovery from Data (TKDD) 2010;4(3):1-21. <https://doi.org/10.1145/1839490.1839495>
- [15]. Kong X, Yu PS. gMLC: a multi-label feature selection framework for graph classification. Knowledge and information systems 2012;31:281-305. doi:10.1007/s10115-011-0407-3
- [16]. Mehmood A, Iqbal M, Mehmood Z, Irtaza A, Nawaz M, Nazir T, et al. Prediction of heart disease using deep convolutional neural networks. Arabian Journal for Science and Engineering 2021;46(4):3409-22. doi:10.1007/s13369-020-05105-1
- [17]. Shaji SP. Prediction and diagnosis of heart disease patients using data mining technique. International Conference on Communication and Signal Processing (ICCSP); 2019 Apr 4; IEEE; 2019. p. 848-52. doi: 10.1109/ICCSP.2019.8697977
- [18]. Anggoro DA, Kurnia ND. Comparison of accuracy level of support vector machine (SVM) and K-nearest neighbors (KNN) algorithms in predicting heart disease. International Journal 2020;8(5):1689-94. <https://doi.org/10.30534/ijeter/2020/32852020>
- [19]. Singh A, Kumar R. Heart disease prediction using machine learning algorithms. International Conference on Electrical and Electronics Engineering (ICE3); 2020 Feb 14; Gorakhpur, India: IEEE; 2020. p. 452-7. doi: 10.1109/ICE348803.2020.9122958
- [20]. Khan MA. An IoT framework for heart disease prediction based on MDCNN classifier. IEEE Access 2020;8:34717-27. doi: 10.1109/ACCESS.2020.2974687
- [21]. Dutta A, Batabyal T, Basu M, Acton ST. An efficient convolutional neural network for coronary heart disease prediction. Expert Systems with Applications 2020;159:113408. <https://doi.org/10.1016/j.eswa.2020.113408>
- [22]. Kim BK, Roh J, Dong SY, Lee SY. Hierarchical committee of deep convolutional neural networks for robust facial expression recognition. Journal on Multimodal User Interfaces 2016;10:173-89. doi:10.1007/s12193-015-0209-0
- [23]. Taylan O, Alkabaa AS, Alqabbaa HS, Pamukçu E, Leiva V. Early prediction in classification of cardiovascular diseases with machine learning, neuro-fuzzy and statistical methods. Biology 2023;12(1):117. <https://doi.org/10.3390/biology12010117>
- [24]. Arif MS, Mukheimer A, Asif D. Enhancing the early detection of chronic kidney disease: A robust machine learning model. Big Data Cogn Comput 2023; 7(3): 144. <https://doi.org/10.3390/bdcc7030144>
- [25]. Mehmood A, Iqbal M, Mehmood Z, Irtaza A, Nawaz M, Nazir T, et al. Prediction of heart disease using deep convolutional neural networks. Arabian Journal for Science and Engineering 2021;46(4):3409-22. doi:10.1007/s13369-020-05105-1