

## Optimizing Video Coding Using Neural Networks: A Comprehensive Review of Methods and Applications

Seyedeh Fatemeh Abdollahi<sup>1</sup>, Seyed Ebrahim Dashti<sup>2</sup>

<sup>1</sup> Faculty of Engineering, Shiraz Branch, Islamic Azad University, Shiraz, Iran

<sup>2</sup> Faculty of Electrical and Computer Engineering, Jahrom Branch, Islamic Azad University

### ABSTRACT

#### RESEARCH PAPER

Received: 3 December 2024

Accepted: 28 April 2025

#### KEYWORDS:

Internet of Things,  
Neural Networks,  
Disease Prediction,  
Recommender System,

<sup>1</sup> Corresponding author:

✉ Sayed.Dashty@gmail.Com

One of the most important applications of the Internet of Things in the field of health is remote patient monitoring. This technology allows doctors to monitor the health status of patients in real time, which is especially crucial for people with or at risk of heart disease. Predicting cardiovascular diseases is known to be a complex challenge that faces low accuracy in existing models. In this research, a new recommender system for predicting cardiovascular diseases is proposed that uses a convolutional neural network to analyze physiological data from patients. Physiological data are collected from patients remotely through four biological sensors, including an ECG sensor, a blood pressure sensor, a heart rate sensor, and a blood glucose sensor. This data is then processed by an Arduino controller, and the convolutional neural network model is used to predict cardiovascular disease. With outstanding capabilities in extracting local features and without the need for complex time sequence analysis, this model can effectively use fixed numerical data such as blood pressure, heart rate, and blood sugar to diagnose heart disease. The experimental results showed that the convolutional neural network was able to effectively extract local and non-temporal features of the data and help the model achieve a prediction accuracy of 98.9%.

نشریه تخصصی آرمان پردازش، دوره ۶، شماره ۱، بهار ۱۴۰۴



فصلنامه تخصصی آرمان پردازش

(APJ)

Homepage: [www.armanprocessjournal.ir](http://www.armanprocessjournal.ir)



فصلنامه تخصصی فناوری اطلاعات و ارتباطات  
شماره مجوز: ۸۷۰۹۰

## پیش‌بینی بیماری‌های قلبی عروقی با استفاده از شبکه عصبی کانولوشنی در سیستم توصیه‌گر مبتنی بر اینترنت اشیا

سیده فاطمه عبدالهی<sup>۱</sup> سید ابراهیم دشتی<sup>۲\*</sup>

۱ دانشکده فنی، واحد شیراز، دانشگاه آزاد اسلامی، شیراز، ایران

۲ دانشکده برق و کامپیوتر، واحد جهرم، دانشگاه آزاد اسلامی

### چکیده

یکی از مهم‌ترین کاربردهای اینترنت اشیا در حوزه سلامت، نظارت بر وضعیت بیماران از راه دور است. این فناوری به پزشکان امکان می‌دهد که به صورت لحظه‌ای وضعیت سلامت بیماران را بررسی کنند و این امر به ویژه برای افراد مبتلا یا مستعد به بیماری‌های قلبی بسیار حیاتی است. پیش‌بینی بیماری‌های قلبی عروقی به عنوان یک چالش پیچیده شناخته می‌شود که با دقت پایین در مدل‌های موجود روبه‌رو است. در این تحقیق، یک سیستم توصیه‌گر جدید برای پیش‌بینی بیماری‌های قلبی عروقی پیشنهاد شده است که از شبکه عصبی کانولوشنی برای تجزیه و تحلیل داده‌های فیزیولوژیکی بیماران استفاده می‌کند. داده‌های فیزیولوژیکی از بیماران به صورت از راه دور از طریق چهار حسگر بیولوژیکی شامل حسگر نوار قلب، حسگر فشار خون، حسگر ضربان قلب و حسگر قند خون جمع‌آوری می‌شوند. این داده‌ها سپس توسط یک کنترل‌کننده آردینو پردازش می‌شوند و مدل شبکه عصبی کانولوشنی برای پیش‌بینی بیماری قلبی عروقی به کار می‌رود، این مدل با قابلیت‌های برجسته در استخراج ویژگی‌های محلی و بدون نیاز به تحلیل پیچیده توالی زمانی، می‌تواند به طور موثری از داده‌های عددی ثابت مانند فشار خون، ضربان قلب، و قند خون برای تشخیص بیماری‌های قلبی استفاده کند. نتایج آزمایش‌ها نشان داد شبکه عصبی کانولوشنی توانسته است ویژگی‌های محلی و غیرزمانی داده‌ها را به طور مؤثری استخراج کرده و به مدل کمک کند تا دقت پیش‌بینی را به ۹۸٫۹٪ برساند.

### مقاله پژوهشی

واژگان کلیدی:

اینترنت اشیا،

شبکه‌های عصبی،

پیش‌بینی بیماری،

سیستم توصیه‌گر.

## مقدمه

بیماری قلبی عروقی که به عنوان CVD نیز شناخته می شود، علت اصلی مرگ و میر است و بیش از ۷۰ درصد از کل مرگ و میرها را شامل می شود. بر اساس مطالعه بار جهانی بیماری در سال ۲۰۱۷، CVD عامل ۴۳ درصد از کل مرگ و میرها است. بر اساس گزارش سازمان جهانی بهداشت (WHO)، بیماری قلبی و سکته مغزی تا سال ۲۰۳۰ باعث مرگ ۲۳،۶ میلیون نفر در سراسر جهان خواهد شد. این آمار ممکن است با تغییرات در سبک زندگی و پیشرفت های پزشکی تغییر کند، اما به طور کلی بیماری های قلبی همچنان به عنوان یکی از بزرگترین چالش های بهداشتی جهان مطرح هستند. در این راستا، تشخیص زودهنگام این بیماری ها می تواند به طور قابل توجهی از آسیب های روانی و جسمی ناشی از آن ها بکاهد و کیفیت زندگی بیماران را بهبود بخشد. از سوی دیگر یکی از عوامل اصلی افزایش هزینه های مراقبت های بهداشتی در کشورهای مختلف، رفتارهای ناسالم مانند کم تحرکی، افزایش مصرف غذا و انتخاب مواد غذایی ناسالم است [۱]، [۲].

اینترنت اشیا با ویژگی های برجسته ای همچون اتصالات بی سیم، حسگری دقیق، قابلیت اطمینان بالا و هوش مصنوعی، به ابزاری حیاتی در زمینه بهداشت و درمان تبدیل شده است. استفاده از دستگاه های پوشیدنی و سنسورها در این حوزه، این امکان را فراهم می آورد که داده های سلامت انسان به طور بلادرنگ جمع آوری و برای پایش و درمان مشکلات قلبی عروقی مورد استفاده قرار گیرد. به طور خاص، پیشرفت های اخیر در تحلیل داده های جمع آوری شده از طریق اینترنت اشیا، به شناسایی دقیق تر و سریع تر بیماری های قلبی کمک کرده است. سیستم های توصیه گر در کاربردهای مختلف محبوبیت پیدا کرده اند. وبسایت های تجارت الکترونیک از این سیستم ها برای پیشنهاد محصولات جدید به کاربران موجود و جدید استفاده می کنند تا آنها را ترغیب به خرید محصولات جدید کنند [۳]، [۴]. فناوری ارتباطات امکان به اشتراک گذاری و انگیزه دادن به فعالیت های بدنی را از طریق سیستم های توصیه گر فراهم کرده است. سبک زندگی سالم و تعادل را می توان در وبسایت های بهداشتی یافت [۵]، [۶].

با توجه به رشد روزافزون استفاده از فناوری های اینترنت اشیا در حوزه بهداشت و درمان، محققان به توسعه سیستم های هوشمند پزشکی ترغیب شده اند. این سیستم ها نه تنها می توانند پیش بینی های دقیق تری از وضعیت سلامتی بیماران ارائه دهند، بلکه می توانند راهکارهای درمانی به روز را نیز پیشنهاد دهند. پیش بینی می شود که بازار بهداشت و درمان مبتنی بر تا سال ۲۰۲۱ به ۱۳۶ میلیارد دلار برسد و این فناوری به ویژه برای جمع آوری داده های

چون ضربان قلب، فشار خون و سطح قند خون در دسترس بیماران قرار گیرد [۷]. این داده ها به طور امن در سرورهای ابری ذخیره می شوند و امکان دسترسی از راه دور و در هر زمان به این داده ها وجود دارد، که به پزشکان این اجازه را می دهد تا تصمیمات درمانی بهتری اتخاذ کنند حسگر IoT معمولاً بر روی بدن بیمار قرار می گیرد تا علائم حیاتی را جمع آوری کند. همانطور که در مطالعات قبلی نشان داده شده است این علائم سپس به برنامه مراقبت های بهداشتی منتقل می شوند و نظارت و پیش بینی بیماری های مزمن به ذینفعان مربوطه مانند بیمارستان ها، مراقبان و افراد اطلاع رسانی می کند تا از خسارات جدی یا دائمی سلامتی جلوگیری شود. در حالی که در این پژوهش فرد بیمار میتواند با دریافت اطلاعات از وضعیت قلب و سلامتی خود، فعالیت های فیزیکی و رژیم غذایی خود را تنظیم کند و از ابتدای مسیر بیماری تحت نظارت و درمان باشد. [۸]، [۹]. در این زمینه در یکی مطالعات پیشین که از سیگنال های صوتی قلب در مطالعات خود استفاده کرده اند نیز با مشکلاتی روبرو هستند چرا که بازسازی یک سیگنال صوتی کامل از یک مشاهده خراب شده بسیار چالش برانگیز است. جداسازی سیگنال HSS از نویز محیطی یکی از موانعی است که باید بر آن غلبه کرد [۱۰].

در حالی که در این پژوهش، استفاده تلفیقی از شبکه های عصبی کانولوشنی و چهار حسگر به عنوان یکی از موثرترین روش ها در پردازش داده های تصویری و پزشکی، می تواند به کاهش خطای تشخیص و بهبود دقت مدل های پیش بینی بیماری های قلبی کمک کند. شبکه عصبی کانولوشنی قادر است ویژگی های پیچیده و غیرخطی موجود در داده های تصویری یا سایر داده های پزشکی را به طور خودکار استخراج کرده و به عنوان یک ابزار کارآمد برای شناسایی ناهنجاری ها و پیش بینی بیماری ها عمل کند. به منظور غلبه بر محدودیت های روش های سنتی و بهبود عملکرد پیش بینی، یک سیستم هوشمند مبتنی بر شبکه های عصبی کانولوشنی پیشنهاد شده است که می تواند برای تشخیص بیماری های قلبی و عروقی و همچنین توصیه های درمانی و تغذیه ای دقیق تر از اینترنت اشیا استفاده کند. بخش های اصلی این مقاله به شرح زیر است:

(۱) به طور اولیه، داده های فیزیولوژیکی از بیمار به صورت دوربرد با استفاده از چهار حسگر بیولوژیکی جمع آوری می شوند، از جمله حسگر نوار قلب، حسگر فشار، حسگر ضربان قلب و حسگر قند خون. یک کنترل کننده آردوینو داده های جمع آوری شده از حسگرهای اینترنت اشیا را دریافت کرده تا بیماری را پیش بینی و تشخیص دهد.

شبکه‌های عصبی کانولوشنی پیشنهادی استفاده می‌شوند. بخش‌های باقی‌مانده از تحقیق به صورت زیر سازمان‌دهی شده‌اند. مطالعات مربوط به تکنیک پیشنهادی در بخش دوم ارائه شده است. روش پیشنهادی به‌طور مختصر در بخش سوم پوشش داده شده و تجزیه و تحلیل و نتایج آزمایش‌ها در بخش چهارم بررسی می‌شود. در نهایت، نتیجه‌گیری و دامنه آینده در بخش پنجم مطرح شده است.

### مطالعات پیشین

در چندین مطالعه، از شبکه‌های عصبی و روش‌های سنتی یادگیری ماشین برای پیش‌بینی بیماری‌های قلبی استفاده شده است. این بخش خلاصه‌ای از چندین تکنیک و روش را ارائه می‌دهد. یعقوب و همکاران [۱۱] یک روش پیش‌بینی بیماری قلبی مبتنی بر یادگیری فدرال با استفاده از طبقه‌بندی ترکیبی پیشنهاد کردند. روش MABC-SVM<sup>۶</sup> مورد ارزیابی قرار گرفت و مشخص شد که دقت پیش‌بینی را ۱٫۵٪ افزایش داده، خطای طبقه‌بندی را ۱٫۶٪ کاهش داده و برای دستیابی به دقت بهینه ۱۷٫۷٪ حلقه کمتری نیاز دارد. صفا و همکاران [۱۲] یک پیش‌بینی هوشمند از بیماری‌های قلبی در زمان واقعی با استفاده از داده‌های کلان پیشنهاد کردند. با استفاده از داده‌های قلبی برای ارزیابی، روش HCBDAV<sup>۷</sup> دقت کلی ۹۶٪ داشت. اگر چه، دقت طبقه‌بندی روش پیشنهادی بسیار پایین است. اوزکان و پگر [۱۳] یک رویکرد مبتنی بر RTA<sup>۸</sup> برای HDP<sup>۹</sup> پیشنهاد دادند. این روش پیشنهادی آزمایش شد و دقت معمولی ۸۷٪ را نشان داد. با این حال، کیفیت تکنیک پیشنهاد شده نیاز به بهبود دارد. بی‌زیمان و همکاران [۱۴] پیش‌بینی بیماری‌های قلبی عروقی را با استفاده از الگوریتم یادگیری ماشین پیشنهاد کردند. یافته‌ها و نتایج آنها دقت کلی ۹۶٫۷٪ را نشان دادند. اگر چه، پیچیدگی محاسباتی رویکرد MLbPM<sup>۱۰</sup> بسیار بالا است. بات و همکاران [۱۵]، یک CDP<sup>۱۱</sup> کارآمد مبتنی بر یادگیری ماشین پیشنهاد شده است. دقت کلی این روش در آزمایش بر روی داده‌های واقعی ۸۷٫۲۸٪ بود. با این حال، پایداری تکنیک پیشنهادی بسیار پایین است.

یک مدل پیش‌بینی بیماری‌های قلبی و عروقی با استفاده از شبکه‌های عصبی کانولوشنی پیاده‌سازی شده است که به تشخیص بیماری‌های قلبی و عروقی پرداخته و آن‌ها را به پنج کلاس موجود تقسیم‌بندی می‌کند: فیبریلاسیون دهلیزی (AF<sup>۱</sup>)، سندرم کرونری حاد (ACS<sup>۲</sup>)، فشار خون بالا (HTN<sup>۳</sup>)، هیپرتروفی بطن چپ (LVH<sup>۴</sup>) و انفارکتوس میوکارد (MI<sup>۵</sup>). در این مدل، از لایه‌های کانولوشن برای استخراج ویژگی‌های محلی و مهم از سیگنال‌های ورودی استفاده می‌شود. سپس، لایه‌های تجمع برای کاهش ابعاد و فشرده‌سازی اطلاعات به کار رفته‌اند. نهایتاً، ویژگی‌های استخراج‌شده از طریق لایه‌های کاملاً متصل برای انجام دسته‌بندی نهایی به پنج کلاس بیماری‌های قلبی و عروقی، با استفاده از تابع فعال‌سازی، طبقه‌بندی می‌شوند.

(۲) روش شبکه‌های عصبی کانولوشنی توصیه‌هایی فیزیکی و غذایی به بیماران قلبی براساس داده‌های طبقه‌بندی شده از طریق یک اپلیکیشن موبایل ارائه می‌دهد که تحقیق را نوآورانه می‌سازد. در مقایسه با روش‌های دیگر، رویکرد شبکه‌های عصبی کانولوشنی دقت بالایی در پیش‌بینی و طبقه‌بندی بیماری‌های قلبی ارائه می‌دهد.

(۳) در این پژوهش بیماران می‌توانند از طریق موبایل خود و بر اساس فاکتورهای شخصی خود رژیم غذایی و برنامه ورزشی دریافت کنند از طرفی تلفیق شبکه‌های عصبی در دریافت اطلاعات از طریق سنسورها باعث افزایش عملکرد و بهبود نتایج شده است. همچنین خوشه‌بندی با استفاده از k-means بیماران را به ۵ کلاس متمایز دسته‌بندی می‌کند. که باعث مدیریت بهتر بیماران در روند پیشگیری و درمان می‌شود.

(۴) صحت، دقت، یادآوری، امتیاز F1 و دقت (پرسنج) از جمله معیارهایی هستند که برای ارزیابی کارایی روش

<sup>7</sup> Health Care Big Data Analytics

<sup>8</sup> Renal Tubular Acidosis

<sup>9</sup> Heart Disease Program

<sup>10</sup> Modified Linear Programming-Based Multi-Objective Optimization

<sup>11</sup> Cardiac Disease Prevention

<sup>1</sup> Atrial Fibrillation

<sup>2</sup> Acute Coronary Syndrome

<sup>3</sup> Hypertension

<sup>4</sup> Left Ventricular Hypertrophy

<sup>5</sup> Myocardial Infarction

<sup>6</sup> Modified Artificial Bee Colony-Support Vector Machine

تا به این مسائل پرداخته و دقت پیش‌بینی مدل‌های یادگیری عمیق را بهبود بخشند. علاوه بر این، مسائل فوق به شدت انگیزه‌دهنده توسعه رویکرد شبکه عصبی کانولوشنی است تا با کمک دستگاه‌های اینترنت اشیا، این مشکل را با پیش‌بینی و طبقه‌بندی بیماری‌های قلبی و عروقی حل کند [۲۵]، [۲۶]، [۲۷]، [۲۸].

شکاف تحقیقاتی: پس از ارزیابی مطالعات پیشین، شکاف‌های تحقیقاتی زیر مربوط به چالش تحقیقاتی پیشنهادی شناسایی شد. (۱) علیرغم اینکه پیش‌بینی بیماری‌های قلبی عروقی اکنون با دقت بسیار بالا ممکن است، اما هنوز چالش‌هایی در پیش‌بینی این بیماری‌ها وجود دارد. تحقیقات همچنان ادامه دارد تا سیستم‌های پیشنهادی نوینی برای پیش‌بینی بیماری‌های قلبی عروقی با استفاده از شبکه‌های اینترنت اشیا ارائه شود که تشخیص، درمان و توصیه‌های رژیمی مؤثری برای بیماری‌های قلبی فراهم کند. تکنیک‌های موجود در پیش‌بینی بیماری‌های قلبی به ویژگی‌های متعددی وابسته‌اند. اکثر تکنیک‌ها از سیستم‌های مبتنی بر یادگیری ماشین، اینترنت اشیا و یادگیری عمیق برای ارزیابی خطر بیماری‌های قلبی عروقی استفاده می‌کنند.

(۲) روش شبکه عصبی کانولوشنی مبتنی بر یادگیری عمیق و اینترنت اشیا می‌تواند به طور قابل توجهی کارایی تشخیص، درمان و توصیه‌های رژیمی برای بیماری‌های قلبی را افزایش دهد. روش شبکه عصبی کانولوشنی این شکاف‌ها را با پیش‌بینی و طبقه‌بندی بیماری‌های قلبی عروقی با استفاده از حسگرهای اینترنت اشیا به صورت زمان و هزینه مؤثر پر می‌کند.

(۳) با این حال، مطالعات پیشین نشان می‌دهد که پیش‌بینی شبکه عصبی کانولوشنی مبتنی بر یادگیری عمیق و اینترنت اشیا می‌تواند به طور قابل توجهی کارایی تشخیص، درمان و توصیه‌های رژیمی برای بیماری‌های قلبی را افزایش دهد. روش پیشنهادی شبکه عصبی کانولوشنی در بسیاری از موارد، به دلیل استفاده از لایه‌های کانولوشن و pooling می‌تواند عملیات‌ها را به‌طور موازی انجام دهد، که منجر به سرعت بالاتر و مقیاس‌پذیری بهتر می‌شود. روش شبکه عصبی کانولوشنی پیشنهادی در بخش بعدی ارائه شده است. مزایا

همچنین، شکلا<sup>۱۲</sup> و همکاران [۱۶] یک واحد دروازه‌ای دو طرفه بهینه‌سازی شده برای سیستم نظارت بر بهداشت در داده‌های کلان پیشنهاد کرده‌اند. روش HMS۱۳ پیشنهادی دقت ۰.۸۳۹۴ و MCC۱۴ برابر با ۰.۷۱۹۴۴۲ را به دست می‌آورد. با این حال، دقت روش HMS پیشنهادی بسیار پایین است.

لو و همکاران [۱۷] یک رادار داپلر را با استفاده از شبکه عصبی بازگشتی دو طرفه برای تشخیص دقیق ضربان قلب پیشنهاد کردند. این روش پیشرفته با امتیاز ۹۵.۶۲٪ F1 در تشخیص ضربان قلب شناخته می‌شود، ولی راهکار پیشنهادی امتیاز F1 بالاتری به مقدار ۹۸.۰۶٪ دارد. با این حال، روش پیشنهادی از نظر محاسباتی پیچیده است. ال‌خووالده و همکاران [۱۸] یک LSTM۱۵ دوجانبه در یک شبکه هم‌پیمانی شبکه‌های عصبی کانولوشنی برای دسته‌بندی آریتمی‌ها پیشنهاد کردند. مدل شبکه‌های عصبی کانولوشنی ۹۸.۰۴٪ دقت و ۱۰۰٪ در تشخیص دقیق موارد مثبت را به دست آورد. اما مدل Deep Residual Bi LSTM۱۶ برای تولید نتایج به زمان اجرای بیشتری نیاز دارد.

اسلام و همکاران [۱۹] یک RNN۱۷ با معماری دوگانه برای طبقه‌بندی ضربان قلب پیشنهاد کردند. روش HARDC۱۸ به صحت ۹۹.۶۰٪، امتیاز F1 ۹۸.۲۱٪، دقت ۹۷.۶۶٪ و یادآوری ۹۹.۶۰٪ دست یافت. با این حال، روش HARDC نیز زمان محاسباتی بالایی دارد. زو و همکاران [۲۰] یک رویکرد یادگیری عمیق عملی و قابل قبول برای تشخیص آریتمی فیبریلاسیون دهلیزی در ضربان قلب‌های بلندمدت پیشنهاد کردند. رویکرد MIF-AFNet۱۹ دقت تشخیص AF قابل مقایسه‌ای برابر با ۹۸.۶۳٪ را هنگام ارزیابی با PhysioNet۲۰ ارائه داد. با این حال، عملکرد روش MIF-AFNet۲۱ نسبتاً ضعیف است. مدل‌های مذکور به دلیل استراتژی‌های ناکافی در یادگیری و بهینه‌سازی، دقت پیش‌بینی پایینی برای بیماری‌های قلبی دارند. به منظور پیش‌بینی سطح ریسک بیماری‌های عروقی، در این مطالعه یک سیستم مبتنی بر اینترنت اشیا (IoT) و یادگیری عمیق توسعه و ارزیابی می‌شود. دقت طبقه‌بندی، پایداری و نرخ پیش‌بینی مدل‌های ذکر شده پایین است [۱]، [۲۱]، [۲۲]، [۲۳]، [۲۴]. بنابراین، مدل‌های موجود نیازمند تحقیقات بیشتری هستند

<sup>18</sup> Hierarchical Attention-based Dual-structured Recurrent Neural Network with Dilated Convolutional Neural Network

<sup>19</sup> Multi-Scale Feature Fusion Attention Mechanism Network

<sup>20</sup> منبع تحقیقاتی برای سیگنال‌های فیزیولوژیک پیچیده

<sup>21</sup> Multi-Scale Feature Fusion Attention Mechanism Network

<sup>12</sup> Shukla

<sup>13</sup> Harmony Search Method

<sup>14</sup> Maximum Correntropy Criterion

<sup>15</sup> Long Short-Term Memory

<sup>16</sup> Deep Residual Bidirectional Long Short-Term Memory

<sup>17</sup> Recurrent Neural Network

و معایب روش پیشنهادی و روش‌های موجود در جدول ۱ نشان داده شده است.

جدول ۱: مزایا و معایب روش پیشنهادی و روش‌های قلبی

نویسنده	روش پیشنهادی	مزایا	معایب
یعقوب و همکاران [۱۱]	MABC-SVM	زمان محاسباتی کمی دارد.	دقت پایین.
صفا و همکاران [۱۲]	HCBD	دقت بالایی برای پیش‌بینی بیماری‌های قلبی دارد.	دقت طبقه‌بندی بسیار پایین است.
اوزجان و پکر [۱۳]	الگوریتم درخت تصمیم برای مدل‌سازی و پیش‌بینی بیماری قلبی	این مدل دقت بالایی در طبقه‌بندی بیماری‌های قلبی دارد.	کیفیت تکنیک پیشنهادی نیاز به بهبود دارد.
بیزمانا و همکاران [۱۴]	MLbPM	عملکرد بسیار بالایی دارد.	پیچیدگی محاسباتی روش MLbPM بسیار زیاد است.
بهات و همکاران [۱۵]	استفاده از تکنیک‌های یادگیری ماشین برای پیش‌بینی موثر بیماری قلبی	این روش از لحاظ محاسباتی کمتر پیچیده است.	مقاومت روش پیشنهادی بسیار پایین است.
شوگلا [۱۶]	HMS	این روش زمان محاسباتی کمی دارد.	دقت روش HMS بسیار پایین است.
لو و همکاران [۱۷]	تشخیص دقیق ضربان قلب با رادار داپلر و شبکه GRU دوطرفه	روش پیشنهادی دقت پیش‌بینی بالایی دارد.	روش پیشنهادی پیچیدگی محاسباتی بالا دارد.
الخوالده و همکاران [۱۸]	DeepResidualBiLSTM	این مدل توانایی قابل توجهی برای تشخیص موارد مثبت دارد.	نیاز به زمان اجرای بیشتر برای تولید نتایج.
اسلام و همکاران [۱۹]	HARDC	این مدل ترکیبی یک استراتژی نوآورانه و مقرون‌به‌صرفه برای فشرده‌سازی سیگنال ECG و تشخیص عملکرد بالا ارائه می‌دهد.	روش HARDC زمان محاسباتی بالایی نیاز دارد.
زو و همکاران [۲۰]	MIF-AFNet	این مدل پتانسیل بهبود تشخیص خودکار فیبریلاسیون دهلیزی را دارد.	کارایی روش MIF-AFNet بسیار پایین است.
Bigru	Bigru	این روش دقت بالایی در پیش‌بینی و طبقه‌بندی بیماری قلبی ارائه می‌دهد.	مدل‌های مبتنی بر یادگیری عمیق از نظر محاسباتی سنگین هستند و پردازش آنی ممکن است به سخت‌افزار قوی نیاز داشته باشد.
	روش پیشنهادی	ویژگی‌های محلی و غیرزمانی داده‌ها را به‌طور مؤثری استخراج کرده و به مدل دقت پیش‌بینی بالایی دارد.	پیچیدگی محاسباتی


بر اساس داده‌های طبقه‌بندی‌شده توسط مدل شبکه عصبی کانولوشنی، سیستم توصیه‌گر به‌طور خودکار توصیه‌هایی در زمینه فعالیت‌های بدنی و تغذیه برای بیماران ارائه می‌دهد. این توصیه‌ها از طریق یک برنامه موبایل برای بیماران ارسال می‌شود تا بتوانند رژیم غذایی و برنامه‌های حرکتی مناسب را دنبال کنند و خطر ابتلا به بیماری‌های قلبی را کاهش دهند.

در این مقاله داده‌ها با چهار سنسور از بیمار دریافت و ارسال می‌شود که این کار ضریب اطمینان و عملکرد را بالا می‌برد در صورتی که در دیگر مقالات مشابه فقط از یک سنسور برای دریافت اطلاعات بیمار استفاده می‌کند و در صورت خرابی یک سنسور کل سیستم از کار می‌افتد. (Malibari, 2023) از طرفی این اطلاعات با صدای قلب رصد می‌شود در صورتی که ما فاکتورهای حیاتی بیشتری را دخیل کرده ایم و این شبکه‌های عصبی همچنین با مکانیزم توجه پیاده‌سازی شده است که دقت و عملکرد را بالاتر کرده است. از طرفی این اطلاعات با صدای قلب رصد می‌شود در صورتی که در این پژوهش فاکتورهای حیاتی بیشتری را دخیل کرده ایم و این شبکه‌های عصبی همچنین با مکانیزم توجه پیاده‌سازی شده است که دقت و عملکرد را بالاتر کرده است. (Muhammad Shafiq, 2023). از نوآوری‌های این پژوهش پیشنهادات غذایی و ورزشی به بیماران قلبی-عروقی بر اساس ویژگی‌های فردی مانند جنسیت و گروه سنی است. شکل ۱، نمودار بلوکی چارچوب پیشنهادی شبکه عصبی کانولوشنی را نشان می‌دهد که به‌وضوح مراحل جمع‌آوری داده، پردازش با شبکه عصبی کانولوشنی و ارائه توصیه‌ها را ترسیم می‌کند. این سیستم پیش‌بینی با استفاده از شبکه عصبی کانولوشنی به‌طور موثر توانایی تشخیص و پیش‌بینی بیماری‌های قلبی عروقی را دارد و می‌تواند به‌عنوان ابزاری کارآمد برای مراقبت‌های بهداشتی و درمان بیماری‌های قلبی مورد استفاده قرار گیرد.

## متدولوژی شبکه عصبی کانولوشنی برای پیش‌بینی بیماری‌های قلبی عروقی

در این بخش، به معرفی متدولوژی شبکه عصبی کانولوشنی پرداخته می‌شود که از شبکه‌های عصبی کانولوشنی برای پیش‌بینی و تشخیص بیماری‌های قلبی عروقی استفاده می‌کند. هدف از این سیستم ایجاد یک سیستم توصیه‌گر مبتنی بر جامعه است که قادر به ارائه تشخیص، درمان و توصیه‌های غذایی برای بیماران مبتلا به بیماری‌های قلبی عروقی باشد. این روش مبتنی بر تحلیل داده‌های فیزیولوژیکی جمع‌آوری‌شده از بیماران به‌صورت از راه دور با استفاده از حسگرهای زیستی پیشرفته است.

در مرحله اول، داده‌های فیزیولوژیکی بیماران از طریق چهار حسگر زیستی مختلف جمع‌آوری می‌شود. این حسگرها می‌توانند پارامترهای مختلفی نظیر ضربان قلب، فشار خون، سطح اکسیژن خون و سایر شاخص‌های حیاتی را در زمان واقعی اندازه‌گیری کرده و برای پردازش‌های بعدی به سیستم منتقل کنند. پس از جمع‌آوری این داده‌ها، مدل پیش‌بینی بیماری‌های قلبی عروقی با استفاده از شبکه‌های عصبی کانولوشنی پیاده‌سازی می‌شود. مدل شبکه عصبی کانولوشنی آموزش خود را با استفاده از داده‌های آموزشی آغاز کرده و از الگوریتم‌های بهینه‌سازی مانند Adam یا SGD (Stochastic Gradient Descent) برای به‌روزرسانی وزن‌ها استفاده می‌کند. با استفاده از داده‌های اعتبارسنجی، عملکرد مدل ارزیابی شده و مدل نهایی برای پیش‌بینی بر روی داده‌های تست استفاده می‌شود. این شبکه‌ها قادرند ویژگی‌های مهم و الگوهای پیچیده در داده‌ها را به‌طور خودکار شناسایی کرده و آن‌ها را به طبقات مختلف بیماری قلبی تقسیم‌بندی کنند. در این سیستم، مدل شبکه عصبی کانولوشنی به تشخیص بیماری‌های قلبی عروقی پرداخته و آن‌ها را به پنج کلاس مختلف تقسیم می‌کند که شامل شرایط مختلف بیماری‌های قلبی است.



شکل ۱: دیاگرام روش پیشنهادی


می‌کنند. پلتفرم الکترونیک آردینو بر اساس اصول خاصی طراحی شده است.

پلتفرم الکترونیکی آردینو بر اساس اصل سخت‌افزار و نرم‌افزار متن‌باز ساخته شده است. این سیستم شامل یک میکروکنترلر، سخت‌افزار برنامه‌پذیر و یک IDE، نرم‌افزار قابل حملی است که برای ایجاد و اضافه کردن کد به برد استفاده می‌شود.


شکل ۲ (a)-(c) خروجی سیگنال سنسور نوار قلب، سنسور فشار، سنسور نبض و سنسور قندخون را نشان می‌دهد که سیگنال‌های الکتریکی، تغییرات فشار و غلظت گلوکز خون را از قلب بیمار ثبت می‌کند تا وضعیت قلبی بیمار را بررسی کند.

### ۱. جمع‌آوری داده‌ها

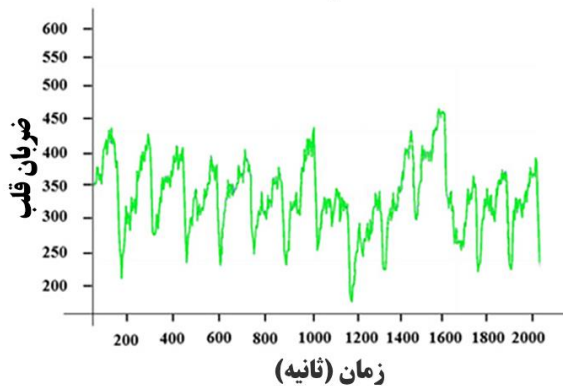
سنسورهای پوشیدنی برای جمع‌آوری داده‌های فیزیولوژیکی بیماران استفاده می‌شوند. داده‌های فیزیولوژیکی با استفاده از سنسورهای پزشکی جمع‌آوری می‌شوند. سنسورهای فشار خون، قند خون، ضربان قلب و نوار قلب به بدن بیمار متصل می‌شوند. هنگام پیش‌بینی بیماری‌های قلبی، فعالیت جسمانی بیمار نشانگر مهمی است. سنسورهای مبتنی بر IoT اطلاعات جمع‌آوری‌شده را به کنترل‌کننده آردینو برای تشخیص و پیش‌آگهی بیماری ارسال




a)



b)



c)



d)

شکل ۲: سیگنال های خروجی از سنسورها

### معماری شبکه عصبی کانولوشنی برای پیش بینی بیماری های قلبی

ساختار اصلی یک شبکه عصبی کانولوشنی از چندین لایه کانولوشن، لایه های Pooling، و لایه های Fully Connected تشکیل می شود. به طور خاص، این مدل شامل مراحل زیر است:

۱. لایه های کانولوشنی: این لایه ها مسئول استخراج ویژگی های محلی از داده های ورودی هستند. به عنوان مثال، در صورتی که داده ها به شکل تصاویر پزشکی باشند، لایه های کانولوشن می توانند ویژگی هایی مانند لبه ها و بافت های موجود در تصاویر قلبی را شناسایی کنند.

فرمول مربوط به اعمال عملیات کانولوشن به صورت زیر است:

$$Y = X * W + b$$

(۱)

که در آن  $X$  داده ورودی،  $W$  وزن های فیلتر کانولوشن، و  $b$  بایاس است.

۲. لایه های Pooling: این لایه ها برای کاهش ابعاد داده ها و همچنین کاهش پیچیدگی محاسباتی طراحی شده اند. این عملیات به حفظ ویژگی های مهم و

### ۲. پیش بینی بیماری های قلبی با استفاده از شبکه عصبی کانولوشنی

مدل پیش بینی بیماری های قلبی عروقی با استفاده از شبکه های عصبی کانولوشنی پیاده سازی شده است که می تواند به تشخیص بیماری های قلبی کمک کند. شبکه های شبکه عصبی کانولوشنی به طور خاص برای پردازش داده های تصویری یا داده های با ساختار فضایی طراحی شده اند و قابلیت شناسایی ویژگی های پیچیده در داده ها را دارند. در این مدل، داده های ورودی می توانند شامل تصاویر پزشکی مانند تصاویر اکوکاردیوگرافی، CT یا MRI یا حتی نمایش های زمان-فرکانس از سیگنال های نوار قلب باشند) شبکه عصبی کانولوشنی قادر است ویژگی های محلی و پیچیده مانند لبه ها، بافت ها، و الگوهای ساختاری را در تصاویر استخراج کرده و بر اساس آن ها پیش بینی های دقیقی انجام دهد.

کاهش وابستگی‌های مکانی کمک می‌کند. در اکثر موارد، از MaxPooling برای کاهش ابعاد استفاده می‌شود.

۳. لایه‌های Fully Connected (FC): پس از استخراج ویژگی‌های پیچیده از طریق لایه‌های کانولوشن، لایه‌های Fully Connected برای ترکیب این ویژگی‌ها و انجام طبقه‌بندی نهایی استفاده می‌شوند. در این مرحله، تمامی استخراج شده به یک یا چند نورون متصل شده و پیش‌بینی نهایی صورت می‌گیرد.

### پیش‌پردازش داده‌ها و ورود به مدل شبکه عصبی کانولوشنی

در ابتدا، داده‌ها باید به صورت مناسب پیش‌پردازش شوند. برای مثال، اگر داده‌ها شامل تصاویر پزشکی از قلب باشند، این تصاویر باید به اندازه مناسب تغییر اندازه داده شده و شدت پیکسل‌ها نرمال‌سازی شوند. در صورتی که داده‌ها شامل سیگنال‌های ECG باشند، می‌توان آن‌ها را به نمایش‌های time-frequency تبدیل کرد تا شبکه عصبی کانولوشنی بتواند ویژگی‌های پیچیده‌ای مانند تغییرات فرکانسی و زمانی را شناسایی کند.

### محاسبه ویژگی‌های مدل شبکه عصبی کانولوشنی

برای آموزش مدل شبکه عصبی کانولوشنی، داده‌ها از طریق لایه‌های مختلف کانولوشن و Pooling عبور کرده و ویژگی‌های مختلفی از جمله لبه‌ها، بافت‌ها و الگوهای ساختاری در تصاویر پزشکی یا سیگنال‌های ECG استخراج می‌شوند. سپس، این ویژگی‌ها به لایه‌های Fully Connected ارسال می‌شوند و مدل بر اساس این ویژگی‌ها تصمیم‌گیری می‌کند.

فرمول‌های مورد استفاده در لایه‌های کانولوشنی و Pooling به صورت زیر است:

اعمال عملیات کانولوشن:

$$b + mnw \cdot \sum_{n=1}^N \sum_{m=1}^M x_{i+m,j+n} = y_{ij}$$

که در آن:

- x داده ورودی
- w وزن‌های فیلتر

- b بایاس

- M و N ابعاد فیلتر

لایه Pooling:

$$\max(x_{i,j}, x_{i+1,j+1}, \dots) = y_{i,j}$$

که در آن بیشترین مقدار از ناحیه انتخاب شده به عنوان خروجی لایه Pooling انتخاب می‌شود.

پایه‌سازی مدل شبکه عصبی کانولوشنی برای پیش‌بینی بیماری‌های قلبی

در این مدل، هدف این است که پس از آموزش شبکه عصبی کانولوشنی، سیستم قادر باشد داده‌های ورودی را به یکی از پنج کلاس بیماری‌های قلبی عروقی طبقه‌بندی کند. این پنج کلاس شامل ACS (Acute Coronary MI (Myocardial Infarction) Syndrome)، AF (Atrial Fibrillation)، HTN (Hypertension) و LVH (Left Ventricular Hypertrophy) هستند. طبقه‌بندی با استفاده از یک لایه Fully Connected در انتهای شبکه انجام می‌شود که نتیجه را به یکی از این پنج کلاس مربوطه تخصیص می‌دهد.

### معماری مدل شبکه عصبی کانولوشنی

مدل شبکه عصبی کانولوشنی می‌تواند شامل لایه‌های زیر باشد:

۱. لایه کانولوشن اول: با استفاده از فیلترهایی برای استخراج ویژگی‌های ابتدایی
۲. لایه Pooling اول: برای کاهش ابعاد و استخراج ویژگی‌های مهم
۳. لایه کانولوشن دوم: برای استخراج ویژگی‌های پیچیده‌تر
۴. لایه Pooling دوم: برای کاهش ابعاد و تمرکز بر ویژگی‌های اصلی
۵. لایه Fully Connected: برای طبقه‌بندی نهایی

## آموزش مدل

جنسیت و گروه سنی ارائه می‌دهد. در این تحقیق، از الگوریتم K-Means برای خوشه‌بندی داده‌ها استفاده شده است.

## خوشه‌بندی مبتنی بر K-Means

برای ایجاد یک سیستم پیشنهاددهی مؤثر برای بیماران قلبی-عروقی از خوشه‌بندی مبتنی بر K-Means استفاده می‌شود. خوشه‌بندی مبتنی بر K-Means داده‌های دسته‌بندی شده به سیستم پیشنهاددهی ارسال می‌شوند که از طریق اپلیکیشن موبایل بیمار، پیشنهادات غذایی و ورزشی را برای بیماران قلبی-عروقی بر اساس جنسیت و گروه سنی ارائه می‌دهد. در این تحقیق، الگوریتم خوشه‌بندی K-Means بسیار مفید است زیرا می‌تواند خوشه‌هایی با اندازه‌های مختلف را شناسایی کند و همچنین با داده‌های متنوع به خوبی کنار بیاید. پس از استفاده از K-Means و بر اساس ارزیابی مبتنی بر امتیاز، همسایگان کاربر  $u$  و کاربران با بالاترین رتبه  $i$  انتخاب می‌شوند. سپس با استفاده از وزن‌های  $w_{uv}$  مربوطه و وزن‌های مشابه  $PC$ ، این فرایند انجام می‌شود. گروه‌های کاربران مبتنی بر ویژگی‌های محتوایی (CB) سپس با استفاده از K-Means ایجاد می‌شوند. این کار با استفاده از معادله (۹) انجام می‌شود، جایی که وزن مشابهت CB مبتنی بر مشابهت کسینوس است. بر اساس CB، بالاترین  $k$  کاربر به عنوان  $i$  دسته‌بندی می‌شوند و به یک خوشه تعلق دارند زیرا کاربر  $u$  همسایه انتخابی است. به طور دوم، نمایندگی کاربر  $x_u$  از فضای ویژگی برای میانگین‌گیری ویژگی‌های اقلام نمایش داده شده است. که در آن نماینده کاربر  $x_u$  نمای فضای ویژگی است که با میانگین‌گیری ویژگی‌های اقلام ایجاد شده است،  $iu$  نشان‌دهنده وزن‌دهی مطابق با امتیاز واقعی ارائه شده است و  $ix$  عنصر  $i$  را نشان می‌دهد. سپس همان وزن‌های  $PC$  که توسط  $w_{uv}$  نمایش داده شده‌اند، تحت معادله (۱) قرار می‌گیرند. جدول ۲ که در بالا ترسیم شده، نمودار رژیم غذایی برای بیماران قلبی را نشان می‌دهد.

جدول ۲: رژیم غذایی برای بیماران قلبی

نوع	مجاز	غیرمجاز
۱	سبزیجات، میوه‌ها، مغزها، روغن‌های گیاهی و لبنیات کم چرب	غذاهای فرآوری شده، شکر، نمک، الکل
۲	همه غلات، میوه‌ها، سبزیجات، ماهی‌های چرب	غذاهای کم نمک و کم شکر، چربی‌های اشباع
۳	میوه‌ها، همه غلات، مغزها، سبزیجات و حیوانات	گوشت قرمز، شیرینی‌ها و نوشیدنی‌ها

مدل شبکه عصبی کانولوشنی آموزش خود را با استفاده از داده‌های آموزشی آغاز کرده و از الگوریتم‌های بهینه‌سازی مانند Adam یا SGD (Stochastic Gradient Descent) برای به‌روزرسانی وزن‌ها استفاده می‌کند. با استفاده از داده‌های اعتبارسنجی، عملکرد مدل ارزیابی شده و مدل نهایی برای پیش‌بینی بر روی داده‌های تست استفاده می‌شود.

## ارزیابی مدل

عملکرد مدل شبکه عصبی کانولوشنی با استفاده از معیارهایی مانند دقت (Accuracy)، حساسیت (Sensitivity)، ویژگی (Specificity) و AUC-ROC ارزیابی می‌شود. این معیارها نشان‌دهنده توانایی مدل در پیش‌بینی دقیق بیماری‌های قلبی هستند.

مدل شبکه عصبی کانولوشنی می‌تواند ویژگی‌های پیچیده‌تری از داده‌های ورودی مانند سیگنال‌های ECG استخراج کرده و به پیش‌بینی دقیق‌تری از بیماری‌های قلبی عروقی منجر شود شبکه عصبی کانولوشنی برای پردازش داده‌های تصویری یا داده‌های ساختاری شده با پیچیدگی‌های فضایی عالی عمل می‌کنند و می‌توانند در تشخیص بیماری‌های قلبی مؤثرتر باشند.

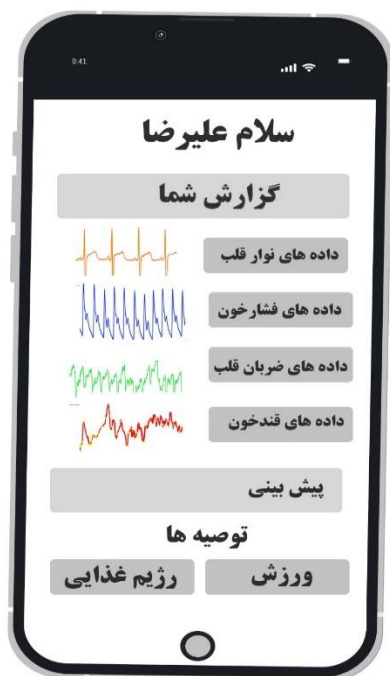
## سیستم پیشنهاددهی شبکه عصبی کانولوشنی با استفاده از

## خوشه‌بندی K-Means

برای توسعه یک سیستم پیشنهاددهی مؤثر برای بیماران قلبی-عروقی، از خوشه‌بندی مبتنی بر ویژگی‌های محتوایی (CB) استفاده می‌شود. داده‌های بیماران به سیستم پیشنهاددهی ارسال می‌شوند و این سیستم از طریق اپلیکیشن موبایل به بیماران قلبی-عروقی پیشنهادات غذایی و ورزشی بر اساس ویژگی‌های فردی مانند

پیش‌بینی کند. شکل ۴ توضیح این مکانیزم را به صورت تصویری نشان می‌دهد.

سیستم توصیه گر کاربر برای دسترسی بلادرنگ به داده‌های بیماران قلبی توسعه یافته است تا نوع بیماری قلبی عروقی را



ب: سیستم توصیه گر کاربر



الف: دسترسی به داده ها به صورت بلادرنگ

شکل ۴: مکانیزم سیستم توصیه گر و اپلیکیشن کاربر

برای این پروژه، دو مجموعه داده شامل مجموعه داده‌های فرامینگهام و استاتالگ قلب انتخاب شدند تا کارایی روش پیشنهادی را نشان دهند که در جدول ۳ نشان داده شده است.

## نتایج و بحث

ادامه سیستم پیشنهادی شبکه عصبی کانولوشنی در این بخش به تفصیل بررسی می‌شود که شامل یافته‌ها نیز می‌باشد.

### A. توصیف مجموعه داده‌ها

نام ویژگی	دامنه
شناسه بیمار	عدد صحیح
جنسیت	{۱ یا ۲}
فشار خون سیستولیک	میلی متر جیوه
فشار خون دیاستولیک	میلی متر جیوه
کلسترول سرم	میلی گرم در ۱۰۰ میلی لیتر
در زمان آزمون پایه	سال‌ها
شاخص توده بدنی	کیلوگرم بر متر مربع
سال آزمون پایه	عدد صحیح
پیگیری بیمار از آزمون پایه	روزها از آزمون پایه
رخداد CHD	۱. = بیمار مبتلا به CAD: ۲ = در غیر این صورت

داده‌های آن تامین شده است. مجموعه داده FHS دارای ۱۵ ویژگی و ۴۲۴۰ مشاهده است.

۱. مجموعه داده فرامینگهام: داده‌های اپیدمیولوژیک مربوط به بیماری‌های قلبی عروقی برای مجموعه داده FHS از مرکز اطلاعات بیوسپسیم NIH و انبار

۲. مجموعه داده استاتلاگ قلب: مجموعه داده استاتلاگ قلب از انبار داده‌های کاگگل استخراج شده است. جدول ۳ نتیجه روش پیشنهادی را توصیف می‌کند.


جدول ۳: مجموعه داده ها

نام ویژگی	دامنه
سن بیمار	عدد صحیح
جنسیت بیمار	[۱ = مرد؛ ۰ = زن]
آنژین القایی توسط ورزش	[۱ = بله؛ ۰ = خیر]
تعداد عروق اصلی	[۰-۳]
نوع درد قفسه سینه	[۱ = تیپیکال؛ ۲ = آتیپیکال؛ ۳ = غیر خاص؛ ۴ = بدون علامت]
فشار خون استراحت	میلی‌متر جیوه
کلسترول سرم	میلی‌گرم در دسی‌لیتر
قند خون ناشتا	$Fbs \geq 120$ میلی‌گرم/دسی‌لیتر [۱ = درست؛ ۰ = نادرست]
نتایج الکتروکاردیوگرام استراحت	[۰ = نرمال؛ ۱ = غیرطبیعی ST-T؛ ۲ = هیپرتروفی بطن چپ]
حداکثر ضربان قلب حاصل شده	عدد صحیح
شیب قله تمرین	[۰ = افزایش؛ ۱ = صاف؛ ۲ = کاهش]
افسردگی ST ناشی از ورزش	عدد
تالاسمی	[۱ = نقص برگشت‌پذیر؛ ۲ = نقص ثابت؛ ۳ = نرمال]
تشخیص بیماری قلبی	[۰ = خیر؛ ۱ = بله]

### B. معیارهای عملکرد

به منظور ارزیابی دقت، صحت، حساسیت، ویژگی و عملکرد اندازه‌گیری در ارتباط با ریسک بیماری قلبی بیماران، عملکرد و قابلیت استفاده از سیستم شبکه عصبی کانولوشنی توسعه‌یافته مورد

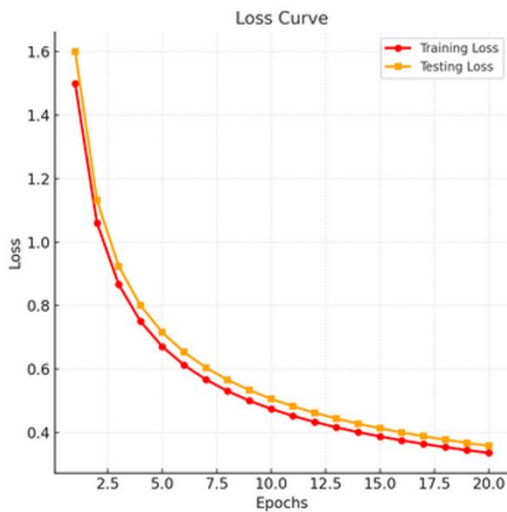
مطالعه قرار گرفت. در شکل ۵، منحنی ROC تولید شده نمایش داده شده است. این نمودار مقایسه‌ای را برای روش‌های مختلف موجود در مقاله شامل شبکه عصبی کانولوشنی و SVM نشان می‌دهد. همان‌طور که مشاهده می‌کنید، روش شبکه عصبی کانولوشنی عملکرد خوبی دارد که نسبت به روش SVM عملکرد بهتری دارد.



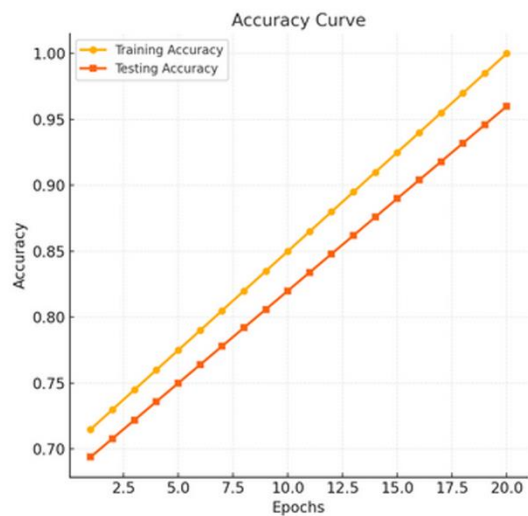
شکل ۵: نمودار ROC

که شبکه عصبی کانولوشنی پیشنهادی دارای نرخ دقت طبقه‌بندی ۹۸,۹۰٪ است. بنابراین، روش پیشنهادی از نظر پیش‌بینی بیماری‌های قلبی عروقی بسیار قابل اعتماد است.

منحنی دقت مدل شبکه عصبی کانولوشنی پیشنهادی [شکل ۶(a)] و منحنی خسارت مدل شبکه عصبی کانولوشنی پیشنهادی [شکل ۶(b)] دقت بالایی که روندهای پیشنهادی شبکه عصبی کانولوشنی در طول آموزش و آزمایش دارند را نشان می‌دهد. نتایج نشان می‌دهد



شکل ۶ (b): منحنی زیان برای روش پیشنهادی

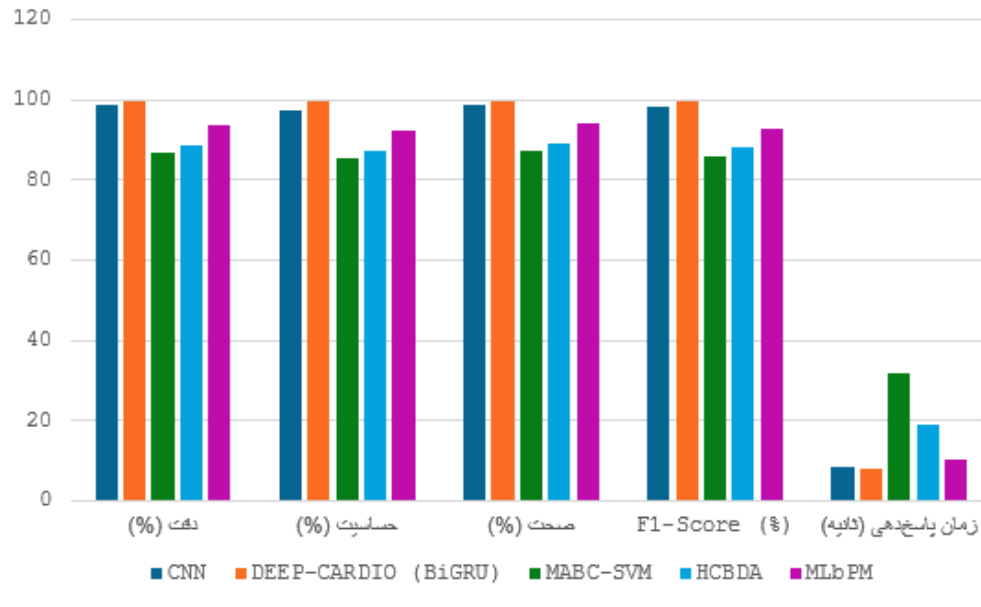


شکل ۶ (a): منحنی صحت برای روش پیشنهادی

### C. تحلیل مقایسه‌ای

برای نشان دادن اینکه روش شبکه عصبی کانولوشنی موثرتر از روش‌های موجود است، عملکرد آن مورد آزمایش قرار گرفته است.

شکل ۷ نرخ پاسخ‌های منفی درست، نمره F1، حساسیت و دقت را نمایش می‌دهد. دقت روش پیشنهادی شبکه عصبی کانولوشنی به ۹۸٫۹۰٪ می‌رسد که ۸۶٫۹۱٪، ۸۸٫۶۵٪ و ۹۳٪ بیشتر از روش‌های موجود مانند MABC-SVM، HCBDA و MLbPM است.



شکل ۷: متریک‌های عملکرد مدل پیشنهادی و روش‌های گذشته

نشان می‌دهد. در ابتدا، مدل پیشنهادی، از نظر دقت و امتیاز F1 برای طبقه‌بندی بررسی می‌شود. این مدل از شبکه عصبی کانولوشنی بهره می‌برد تا ویژگی‌های پیچیده داده‌های سری زمانی را استخراج کند و اختلالات قلبی عروقی را پیش‌بینی و دسته‌بندی کند. شبکه عصبی کانولوشنی با اعمال فیلترهای مختلف، ویژگی‌های محلی و الگوهای خاص داده‌های سری زمانی را شناسایی کرده و برای طبقه‌بندی آماده می‌کند. به این ترتیب، شبکه عصبی کانولوشنی می‌تواند داده‌های سنسور را به‌طور کارآمد پردازش کرده و ویژگی‌های مهم را استخراج کند. در نتیجه، این مدل قادر است گزارش را به پنج کلاس قلبی عروقی شامل MI، ACS، AF، HTN و LVH با دقت بالا دسته‌بندی کند. از این تجزیه و تحلیل فرسایش، مدل شبکه عصبی کانولوشنی پیشنهادی با مکانیزم توجه به دقت بالایی برای طبقه‌بندی بیماری‌های قلبی دست می‌یابد.

شکل ۷ مقایسه گرافیکی از معیارهای مختلف، از جمله دقت، حساسیت و نمره F1 را بین رویکردهای پیشنهاد شده و پیشنهادی ارائه می‌دهد. دقت تکنیک روش شبکه‌های کانولوشنی است ۹۸٫۲٪ دقت دارد، که نسبت به دیگر روش‌های موجود عملکرد بهتری را نشان می‌دهد.

### D. مکانیزم توجه

طبق تحقیقات اختلالات قلبی عروقی شناسایی و آن‌ها را به پنج گروه مختلف قلبی عروقی دسته‌بندی شد، با استفاده از مدل شبکه عصبی کانولوشنی. طبق مقایسه‌ای، دقت طبقه‌بندی برای بیماری‌های قلبی عروقی در جدول ۵ نشان داده شده است. مدل‌های توجه معمولاً بدون لایه‌های کانولوشن و ساختار شبکه عصبی کانولوشنی، دقت کمتری داشتند، که این امر اهمیت لایه‌های شبکه عصبی کانولوشنی در طبقه‌بندی بیماری‌های قلبی عروقی را جدول ۵: دقت طبقه بندی در روش پیشنهادی شبکه عصبی کانولوشنی

معیار	شبکه عصبی کانولوشنی با مکانیزم توجه	شبکه عصبی کانولوشنی بدون مکانیزم توجه
صحت	۹۴,۰۸	۹۱,۰۳
F1-Score	۹۴,۰۵	۹۰,۹

## تشکر و قدردانی

بنده از راهنمایی و حمایت بی دریغ استاد راهنما در طول این تحقیق صمیمانه سپاسگزارم.

## منابع

- [1] Shukla S, Neduncheliyan S. Predicting Cardiovascular Disease Through IoT and Deep Learning Methods. In 2024 4th International Conference on Sustainable Expert Systems (ICSES) 2024 Oct 15 (pp. 250-255). IEEE.
- [2] Thorpe KE. The future costs of obesity: National and state estimates of the impact of obesity on direct health care expenses. A collaborative report from United Health Foundation. 2009.
- [3] Michie S, West R, Campbell R, Brown J, Gainforth H. ABC of behaviour change theories: an essential resource for researchers. Policy Makers and Practitioners. 2014;402.
- [4] Linden G, Smith B, York J. Amazon. com recommendations: Item-to-item collaborative filtering. IEEE Internet computing. 2003 Feb 28;7(1):76-80.
- [5] Konrad A, Bellotti V, Crenshaw N, Tucker S, Nelson L, Du H, Pirolli P, Whittaker S. Finding the adaptive sweet spot: Balancing compliance and achievement in automated stress reduction. In Proceedings of the 33rd Annual ACM Conference on Human Factors in Computing Systems 2015 Apr 18 (pp. 3829-3838).
- [6] Bharadhwaj H. Meta-learning for user cold-start recommendation. In 2019 International Joint Conference on Neural Networks (IJCNN) 2019 Jul 14 (pp. 1-8). IEEE.
- [7] Wei X, Rao C, Xiao X, Chen L, Goh M. Risk assessment of cardiovascular disease based on SOLSSA-CatBoost model. Expert systems with applications. 2023 Jun 1;219:119648.

شبکه های عصبی با مکانیزم توجه عملکرد بهتری داشته و از دقت و امتیاز F1 بالاتری برخوردار است. مکانیزم توجه به تمرکز روی ویژگی های مهم داده کمک می کند. در حالی که این روش بدون مکانیزم توجه عملکرد کمتری نشان داده است که نشان دهنده اهمیت مکانیزم توجه در بهبود طبقه بندی است.

## نتیجه گیری

این مقاله روش شبکه عصبی کانولوشنی را پیشنهاد می کند که برای سیستم توصیه گر مبتنی بر جامعه ایجاد شده است که تشخیص، درمان و توصیه های غذایی را برای بیماری های قلبی ارائه می کند. روش پیشنهادی شبکه عصبی کانولوشنی با استفاده از شبیه ساز ابر (CloudSim) شبیه سازی شده است. عملکرد این روش با استفاده از مجموعه داده های بیماری قلبی فرامینگهام و استاتلوج اعتبارسنجی شده است. مقایسه ای بین رویکرد شبکه عصبی کانولوشنی پیشنهادی و رویکردهای موجود، مانند MABC-SVM، HCBDA، و MLbPM از نظر صحت، دقت، یادآوری و حساسیت انجام شده است. دقت روش پیشنهادی ۹۸,۹۰ درصد بیشتر از روش MABC-SVM است که به ترتیب ۸۶,۹۱ درصد، روش HCBDA که ۸۸,۶۵ درصد است و روش MLbPM که ۹۳,۶۳ درصد است. روش شبکه عصبی کانولوشنی بهتر از دیگر روش ها عمل می کند. در این روش داده های سلامت بلادنگ از دستگاه های اینترنت اشیا ممکن است حاوی نویز، مصنوعات یا خطاهایی باشد که می تواند بر عملکرد مدل تأثیر منفی بگذارد. شرایط سلامتی بیمار می تواند به صورت پویا تغییر کند. بنابراین، الگوریتم باید با این تغییرات تطبیق داده و با وجود تغییرات در پارامترهای سلامت، پیش بینی های قابل اعتمادی را ارائه دهد. در آینده، رویکرد شبکه عصبی کانولوشنی با انجام آزمایش های بیشتر برای تشخیص بیماری عروق کرونر قلب با استفاده از الگوریتم های انتخاب عملکرد و سایر تکنیک های بهینه سازی، بر محدودیت های فوق غلبه خواهد کرد.

- [18] Alkhalwaldeh RS, Al-Ahmad B, Ksibi A, Ghatasheh N, Abu-Taieh EM, Aldehim G, Ayadi M, Alkhalwaldeh SM. Convolution neural network bidirectional long short-term memory for heartbeat arrhythmia classification. *International Journal of Computational Intelligence Systems*. 2023 Dec 19;16(1):197.
- [19] M. S. Islam et al., "HARDC : A novel ECG-based heartbeat classification method to detect arrhythmia using hierarchical attention based dual structured RNN with dilated CNN," *Neural Netw.*, vol. 162, pp. 271–287, May 2023.
- [20] Zou Y, Yu X, Li S, Mou X, Du L, Chen X, Li Z, Wang P, Li X, Du M, Fang Z. A generalizable and robust deep learning method for atrial fibrillation detection from long-term electrocardiogram. *Biomedical Signal Processing and Control*. 2024 Apr 1;90:105797.
- [21] Islam R, Abid MK, Aziz Y, Naeem A, Aslam N. Hybrid FNN-DNN approach for early detection of cardiac arrhythmia: A novel framework for enhanced diagnosis. *VAVKUM Transactions on Computer Sciences*. 2024 May 18;12(1):48-64.
- [22] Nancy AA, Ravindran D, Vincent DR, Srinivasan K, Chang CY. Fog-based smart cardiovascular disease prediction system powered by modified gated recurrent unit. *Diagnostics*. 2023 Jun 15;13(12):2071.
- [23] Talukdar J, Singh TP. Early prediction of cardiovascular disease using artificial neural network. *Paladyn, Journal of Behavioral Robotics*. 2023 Feb 17;14(1):20220107.
- [24] Rajkumar G, Devi TG, Srinivasan A. Heart disease prediction using IoT based framework and improved deep learning approach: medical application. *Medical engineering & physics*. 2023 Jan 1;111:103937.
- [25] Zafar S, Iftekhhar N, Yadav A, Ahilan A, Kumar SN, Jeyam A. An IoT method for telemedicine: Lossless medical image compression using local adaptive blocks. *IEEE Sensors Journal*. 2022 Jun 24;22(15):15345-52.
- [26] Dakshina DS, Della Reasa V, Bindhu A. Alzheimer disease detection via deep learning-based shuffle network. *International Journal of Current Bio-Medical Engineering*. 2023;1(1):9-15.
- [8] Paul B, Karn B. Heart disease prediction using scaled conjugate gradient backpropagation of artificial neural network. *Soft Computing*. 2023 May;27(10):6687-702.
- [9] Malibari AA. An efficient IoT-Artificial intelligence-based disease prediction using lightweight CNN in healthcare system. *Measurement: Sensors*. 2023 Apr 1;26:100695.
- [10] Shafiq M, Du C, Jamal N, Abro JH, Kamal T, Afsar S, Mia MS. Smart E-Health System for Heart Disease Detection Using Artificial Intelligence and Internet of Things Integrated Next-Generation Sensor Networks. *Journal of Sensors*. 2023;2023(1):6383099.
- [11] Yaqoob MM, Nazir M, Khan MA, Qureshi S, Al-Rasheed A. Hybrid classifier-based federated learning in health service providers for cardiovascular disease prediction. *Applied Sciences*. 2023 Feb 1;13(3):1911.
- [12] Safa M, Pandian A, Gururaj HL, Ravi V, Krichen M. Real time health care big data analytics model for improved QoS in cardiac disease prediction with IoT devices. *Health and Technology*. 2023 Jun;13(3):473-83.
- [13] Ozcan M, Peker S. A classification and regression tree algorithm for heart disease modeling and prediction. *Healthcare Analytics*. 2023 Nov 1;3:100130.
- [14] P. C. Bizimana, Z. Zhang, M. Asim, and A. A. A. El-Latif, "An effective machine learning-based model for an early heart disease prediction," *BioMed Res. Int.*, vol. 2023, pp. 1–11, Apr. 2023.
- [15] Bhatt CM, Patel P, Ghetia T, Mazzeo PL. Effective heart disease prediction using machine learning techniques. *Algorithms*. 2023 Feb 6;16(2):88.
- [16] Shukla PK, Stalin S, Joshi S, Shukla PK, Pareek PK. Optimization assisted bidirectional gated recurrent unit for healthcare monitoring system in big-data. *Applied Soft Computing*. 2023 May 1;138:110178.
- [17] Lu H, Heyder M, Wenzel M, Albrecht NC, Langer D, Koelpin A. Accurate heart beat detection with Doppler radar using bidirectional GRU network. In *2023 IEEE Radio and Wireless Symposium (RWS)* 2023 Jan 22 (pp. 52-54). IEEE.

[27] Ahilan A, Rejula MA, Kumar SN, Kumar BM. Virtual reality sensor-based IoT embedded system for stress diagnosis. *IEEE Sensors Journal*. 2023 Sep 18;23(23):29425-33.

[28] Murugan TM, Jeyam A. IoT-enabled protein structure classification via CSA-PSO based CD4. 5 classifier. *Int. J. Data Sci. Artif. Intell.* 2023;1(2):41-51.

---

#### COPYRIGHTS

©2025 by the authors. Published by the **Islamic Azad University, Khodabandeh Branch, Zanjan**. This article is an open-access article distributed under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0) <https://creativecommons.org/licenses/by/4.0>

---

