



## Detection of Cardiac Arrhythmias from ECG Signals Using a Deep Neural Network Based on the InceptionNet Architecture and the Bat Optimization Algorithm

Alireza Zarei\*

M.Sc. in Biomedical Engineering, Imam Reza International University, Mashhad, Iran.

Elaheh Javidnezhad

Undergraduate Student of Biomedical Engineering, Apadana Institute of Higher Education, Shiraz, Iran.

### Abstract

In recent decades, the automated detection of cardiac arrhythmias from electrocardiogram (ECG) signals has been extensively investigated. Continuous development and improvement of open-access ECG databases, such as the MIT-BIH Arrhythmia Database and the SLPDB database, have significantly facilitated heartbeat-level analysis using ECG signals. Numerous approaches have been proposed to classify heartbeats into the five standard classes defined by the Association for the Advancement of Medical Instrumentation (AAMI). These classes include Normal beats (N), Supraventricular Ectopic Beats (SVEB), Ventricular Ectopic Beats (VEB), Fusion beats (F), and Unknown beats (Q), which enable the differentiation of various heartbeat waveform morphologies. In the proposed approach of this study, initial preprocessing steps are first applied to the ECG signals. After data normalization, the Bat Optimization Algorithm is employed for dimensionality reduction, as well as for the selection and extraction of key features relevant to cardiac arrhythmia detection. Subsequently, for accurate and final classification, a convolutional neural network-based classifier utilizing the InceptionNet architecture is implemented as a deep learning technique. Finally, in the simulation stage, established evaluation metrics are used to validate the proposed approach and to compare its performance with that of previously reported studies.

**Keywords:** Cardiac Arrhythmia, ECG Signal, InceptionNet Neural Networks, Deep Learning, Bat Optimization Algorithm.

Received: 23/December/2026

Accepted: 19/February/2026

eISSN: 3115-7610

ISSN: 3115-7572

## تشخیص آریتمی قلبی از سیگنال‌های ECG با رویکرد شبکه عصبی عمیق InceptionNet و الگوریتم بهینه‌سازی خفاش

علیرضا زارعی\*

کارشناسی ارشد مهندسی پزشکی، دانشگاه بین‌المللی امام رضا(ع)، مشهد، ایران.

الهه جاویدنژاد

دانشجوی کارشناسی مهندسی پزشکی، مؤسسه آموزش عالی آپادانا، شیراز، ایران.

### چکیده

در دهه‌های گذشته، تشخیص خودکار آریتمی از سیگنال‌های الکتروکاردیوگرام (ECG) به‌طور گسترده مورد بررسی قرار گرفته است. توسعه و بهبود مداوم پایگاه‌های داده منبع‌باز الکتروکاردیوگرام، مانند پایگاه داده آریتمی مؤسسه فناوری ماساچوست (MIT-BIH) و پایگاه داده SLPDB، تحلیل سطح ضربان قلب از طریق ECG را بیش از پیش در دسترس قرار داده است. تاکنون روش‌های متعددی به‌منظور تفکیک ضربان‌های قلب به پنج کلاس اصلی استاندارد AAMI ارائه شده است؛ این کلاس‌ها شامل ضربان نرمال، ضربان نابه‌جای فوق‌بطنی (SVEB)، ضربان نابه‌جای بطنی (VEB)، ضربان تلفیقی (فیوژن) و ضربان ناشناخته است که به کمک آن‌ها می‌توان شکل موج‌های ضربان قلب را از یکدیگر متمایز کرد. رویکرد پیشنهادی در این پژوهش بدین صورت است که ابتدا پیش‌پردازش‌های اولیه روی سیگنال انجام می‌گیرد. پس از نرمال‌سازی داده‌ها، از الگوریتم بهینه‌سازی خفاش برای کاهش ابعاد، انتخاب و استخراج ویژگی‌های کلیدی جهت تشخیص آریتمی قلبی استفاده می‌شود. سپس، به‌منظور تشخیص دقیق و نهایی، از یک طبقه‌بند مبتنی بر شبکه عصبی کانولوشن (InceptionNet) به‌عنوان تکنیک یادگیری عمیق بهره گرفته می‌شود. در انتها، در بخش شبیه‌سازی از معیارهای ارزیابی معتبر برای اعتبارسنجی رویکرد پیشنهادی و مقایسه عملکرد آن با پژوهش‌های پیشین استفاده شده است.

کلیدواژه‌ها: آریتمی قلبی، سیگنال ECG، شبکه‌های عصب InceptionNet، یادگیری عمیق، الگوریتم بهینه‌سازی خفاش

## مقدمه

طبق گزارش سازمان جهانی بهداشت، بیماری‌های قلبی-عروقی شایع‌ترین علت مرگ‌ومیر جهانی هستند. آریتمی قلبی، به‌عنوان یکی از انواع این بیماری‌ها، ناشی از اختلال در پالس‌های الکتریکی هماهنگ کننده ضربان قلب است که منجر به تپش بیش از حد سریع، کند یا نامنظم می‌شود. برخی آریتمی‌ها حیات‌محور بوده و با کاهش پمپاژ خون، به مغز، قلب و سایر اندام‌ها آسیب می‌رسانند. تشخیص زودهنگام و مراقبت فوری می‌تواند مرگ ناگهانی را به‌طور قابل توجهی کاهش دهد؛ باین‌حال، مراحل اولیه اغلب بدون علامت بوده و علائم مشابه با سایر بیماری‌های قلبی، تشخیص را دشوار می‌سازد. لذا، توسعه سیستم هوشمند برای شناسایی دقیق ضروری است.

روش‌های هوشمند موجود در تشخیص آریتمی مبتنی بر الکتروکاردیوگرام (ECG) با چالش‌هایی نظیر دقت پایین، استفاده از داده‌های محدود و قدیمی و نیز عدم توجه به عوامل خطر متعدد مواجه‌اند. ECG تنها یکی از مراحل تشخیص است و تفسیر نادرست آن ممکن است رخ دهد؛ درحالی‌که روش‌های تکمیلی مانند اکوکاردیوگرام، هولترمانیتورینگ، تست ورزش، الکتروفیزیولوژی و کاتتریزاسیون قلبی به‌منظور تشخیص جامع ضروری‌اند. حجم بالای داده‌های حاصل از این آزمون‌ها، فرایند تصمیم‌گیری بالینی را پیچیده کرده و خطر خطای انسانی را افزایش می‌دهد. بنابراین، مدل هوشمندی با قابلیت یکپارچه‌سازی عوامل پیش‌زمینه و داده‌های چندمنبعی، دقت تشخیص را ارتقا خواهد داد.

ادامه مقاله به‌صورت زیر سازمان‌دهی می‌شود. در مرور پژوهش‌ها برخی روش‌های اخیر برای تشخیص آریتمی قلبی از طریق سیگنال‌های الکتروکاردیوگرام و پایگاه‌داده‌های بالینی بررسی می‌شوند. روش پیشنهادی رویکرد جدیدی برای آریتمی قلبی براساس شبکه عصبی عمیق<sup>۱</sup> InceptionNet و الگوریتم بهینه‌سازی خفاش ارائه می‌کند. سپس یک شبیه‌سازی در محیط MATLAB<sup>۲</sup> با سیگنال‌های الکتروکاردیوگرام انجام می‌شود که توسط یک مجموعه داده استاندارد تقویت می‌شود. نهایتاً نتیجه‌گیری کل مقاله ارائه می‌شود.

## پیشینه پژوهش

الگوریتم‌های یادگیری ماشینی کاربردهای فراوانی در زمینه سلامت دارد تا ریسک بیماری، تشخیص، ناهنجاری و احتمال پاسخ‌دهی به درمان را پیش‌بینی کند. برای مثال، داده‌های کلیدی برای پیش‌بینی نرخ زنده ماندن بیماران به‌کاررفته است. آریتمی قلبی به معنی غیرطبیعی بودن ریتم قلب است. ریتم طبیعی قلب از گره سینوسی آغاز شده و پس از انتقال به گره دهلیزی-بطنی در بطن‌ها منتشر می‌شود. ویژگی‌های بررسی شده در پژوهش [۱] در روش پیشنهادی در ابتدا سیگنال‌های الکتروکاردیوگرام برای حذف سروصدا پیش‌پردازش می‌شوند. سپس انحرافات موجود در سیگنال‌ها شناسایی می‌شود و با استفاده از آن مجموعه امواج طبیعی قلب شناسایی می‌شود که ویژگی بسیار مهمی در شناسایی آریتمی‌ها است. یک شبکه عصبی مصنوعی شامل اتصالاتی از نورون‌های مصنوعی است که تابع هدف را مورد بررسی قرار می‌دهند. پس از پیش‌پردازش عمل استخراج ویژگی صورت می‌گیرد. سپس با استفاده از شبکه‌های عصبی مصنوعی بیماری آریتمی قلبی تشخیص داده می‌شود. شبکه عصبی پیشنهادی یک شبکه عصبی روبه‌جلو است که از یک لایه ورودی، یک لایه پنهان و یک لایه خروجی تشکیل شده است. برای آموزش شبکه عصبی از ۲۰ مجموعه داده حاوی ویژگی‌های QRS، استفاده می‌شود. سیستم پیشنهادی به دقت ۹۸/۴۸٪ دست یافته است [۱].

1. Inception convolutional neural network (InceptionNet)  
2. Matrix laboratory (MATLAB)

وانگ و همکاران<sup>۱</sup> [۲]، روش جدیدی برای طبقه‌بندی آریتمی‌های قلبی بر مبنای تبدیل ویولت و شبکه‌های عصبی ارائه کرده‌اند. از تبدیل ویولت گسسته جهت پردازش رکوردهای سیگنال‌های الکتروکاردیوگرام و استخراج ویژگی‌های زمان و فرکانس استفاده می‌شود. نتیجه‌ی به‌دست آمده به‌عنوان بردار ورودی برای آموزش و تست یک شبکه‌ی عصبی مورد استفاده قرار می‌گیرد. در این تحقیق از ۲۰ رکورد موجود در پایگاه داده استاندارد در قالب ۴۲۰ نمونه سیگنال استفاده شده است. نتایج شبیه‌سازی نشان می‌دهد که سیستم طراحی شده با استفاده از یک شبکه‌ی عصبی پرسپترون چندلایه به‌عنوان طبقه‌بندی کننده از دقت بالایی برخوردار می‌باشد و می‌تواند ۴ کلاس آریتمی را با دقت بیش از ۹۷٪ طبقه‌بندی کند [۲].

زو و همکاران<sup>۲</sup> [۳] یک طرح طبقه‌بندی سیگنال الکتروکاردیوگرام برای تشخیص آریتمی قلب است که شامل یکی از روش‌های کاهش ویژگی، ترکیب تجزیه و تحلیل مؤلفه اصلی و یک طبقه‌بندی احتمالی شبکه عصبی برای طبقه‌بندی هشت نوع مختلف آریتمی قلب است. برای کاهش ابعاد ویژگی از روش‌های تحلیل مؤلفه اصلی و تجزیه و تحلیل خطی استفاده می‌شود. در طبقه‌بندی آریتمی قلب از ۲۰۰ نمونه داده استفاده شده است که مربوط به سال ۱۹۸۰ می‌باشد. بیشترین دقت طبقه‌بندی برای سیستم پیشنهادی ۹۹/۷۱٪ به‌دست آمده است [۳].

خلف و همکاران<sup>۳</sup> [۴]، یک روش خوشه‌بندی چندطبقه براساس الگوریتم خوشه‌بندی حداکثر حاشیه و الگوریتم تکاملی برای تشخیص آریتمی قلب ارائه شده است. پایگاه داده استفاده شده شامل ۵ نوع مختلف آریتمی شامل ریتم سینوسی طبیعی، بلوک انقباض زودرس، انقباض زودرس دهلیزی، هم‌جوشی بطن و ضربان طبیعی می‌باشد. سیستم تشخیص آریتمی قلب توسط سه بخش ساخته شده است، از جمله پیش‌پردازش، استخراج ویژگی و طبقه‌بندی. در مرحله اول، سیگنال الکتروکاردیوگرام خام قبل از فیلتر جمع‌آوری می‌شود و سپس جهت شناسایی شکل موج‌ها پردازش می‌شوند. در مرحله پیش‌پردازش، حذف صدا برای هر رکورد انجام می‌شود. مرحله دوم استخراج ویژگی است که هدف آن یافتن بهترین ضرایب تعیین شده برای توصیف سیگنال الکتروکاردیوگرام است. مرحله آخر طراحی شده است تا با استفاده از الگوریتم خوشه‌بندی چندطبقه عمل تشخیص آریتمی قلب صورت گیرد. به‌طور تصادفی ۱۳۰ داده که شامل ۷۰٪ داده‌ها می‌باشد برای آموزش و ۵۵ داده که شامل ۳۰٪ داده‌ها می‌باشد، جهت تست سیستم استفاده شده‌اند. سه روش حساسیت، خاصیت و دقت جهت ارزیابی عملکرد سیستم استفاده شده است. میزان حساسیت، خاصیت و دقت به ترتیب ۸۲/۴٪، ۹۸/۸٪ و ۹۷/۴٪ به‌دست آمده است [۴]. میترا و همکاران<sup>۴</sup> [۵] یک سیستم تشخیص کامپیوتری برای طبقه‌بندی پنج ضربان قلب ارائه شده است. موارد بررسی شده شامل ضربان نرمال، انقباض زودرس بلوک، انقباض زودرس کم‌ری، بلوک سمت چپ و بلوک سمت راست می‌باشد. در این مقاله، از دو روش برای کاهش فضای ویژگی استفاده شده است که شامل تجزیه و تحلیل مؤلفه اصلی و انتخاب ویژگی می‌باشد. در روش تجزیه و تحلیل مؤلفه اصلی مبتنی بر فیلتر از ترکیب خطی ویژگی‌های ورودی و واریانس استفاده می‌کند. در روش انتخاب ویژگی هریک از ویژگی‌ها به‌طور مستقل ارزیابی می‌شود. پایگاه داده استفاده شده شامل ۳۰ دقیقه ضبط ضربان قلب می‌باشد. ۳۶۳ داده در پژوهش حاضر استفاده شده است. پارامترهای بلوک شاخه سمت چپ، بلوک شاخه راست، انقباضات زودرس بطنی، نارسایی انقباضات دهلیزی و ضربان زودرس در پژوهش حاضر بررسی شده است. جهت اعتبارسنجی سیستم پیشنهادی از روش اعتبارسنجی ۱۰ بخشی استفاده شده است. برای روش پیشنهادی مقادیر حساسیت، ویژگی، دقت به ترتیب ۹۹/۲۰٪، ۹۸/۶۰٪ و ۹۷/۶۰٪ به‌دست آمده است [۵].

1. Wang et al.  
2. Zhu et al.  
3. Khalaf et al.  
4. Mitra et al.

جداو<sup>۱</sup> براساس [۶] ارائه رویکرد جدیدی برای طبقه‌بندی بیماری آریتمی قلبی می‌باشد. در این مطالعه از روش ترکیبی انتخاب ویژگی مبتنی بر همبستگی و شبکه عصبی برگشتی استفاده شده است. هدف از این پژوهش طبقه‌بندی آریتمی قلب به دو بخش وجود آریتمی و نبود آریتمی می‌باشد. پایگاه داده‌ی استفاده شده شامل ۴۲۰ نمونه است. مجموعه داده‌های استفاده شده به سه دسته تقسیم می‌شوند: مجموعه داده‌های آموزش (۶۸٪)، مجموعه داده‌های اعتبارسنجی (۱۶٪) و مجموعه داده‌ی تست (۱۶٪). اساساً این مطالعه شامل دو مرحله است: مرحله استخراج ویژگی و مرحله کاهش با استفاده از همبستگی انتخاب ویژگی و طبقه‌بندی توسط شبکه‌های عصبی گسترش یافته روبه‌عقب. نتایج تجربی ارائه شده در این مقاله نشان می‌دهد دقت طبقه‌بندی با استفاده از میانگین ۱۰۰ شبیه‌سازی ۸۷/۷۱٪ به‌دست آمده است [۶]. مارتیس<sup>۲</sup> [۷] به تشخیص آریتمی قلب با طبقه‌بندی آن به حالت عادی و کلاس‌های غیرطبیعی پرداخته است. در داده‌های ضبط شده، سیگنال‌های الکتروکاردیوگرام استاندارد دارای ۱۲ ویژگی به‌منظور تشخیص آریتمی قلب بوده است. داده‌های استفاده شده شامل ۲۷۹ نمونه می‌باشد. ۹۰٪ داده‌ها جهت آموزش سیستم و ۱۰٪ داده‌ها جهت تست سیستم استفاده شده‌اند. دقت طبقه‌بندی براساس مساحت زیر منحنی ۹۱/۱۱٪ به‌دست آمده است [۷]. یائو<sup>۳</sup> [۸] یک روش کلی برای تشخیص خودکار آریتمی قلب ارائه شده است که از روش‌های K نزدیک‌ترین همسایه، درخت تصمیم و شبکه عصبی مصنوعی استفاده شده است و برای طبقه‌بندی دقیق ناهنجاری‌های قلب به کار برده شده‌اند. در این تحقیق، دو پایگاه داده آریتمی و فیبریلاسیون استفاده شده است. در پایگاه داده، ۱۲۰۰ ضربان قلب در ۳۶۰ نمونه بررسی شده است. جهت اعتبارسنجی سیستم از روش اعتبارسنجی ۱۰ بخشی استفاده شده است. روش پیشنهادی با استفاده نرم‌افزار متلب شبیه‌سازی شده است. K نزدیک‌ترین همسایه بالاترین کارایی را داشته و به دقت ۹۹/۴۵٪ رسیده است. کلواد<sup>۴</sup> [۹] تشخیص آریتمی چند از الکتروکاردیوگرام با استفاده از شبکه عصبی کانولوشن براساس زمان توجه به نمونه‌برداری، ارائه شده است که از مجموعه داده‌های سیگنال گفتار<sup>۵</sup> استفاده نموده است و دقت آن برابر ۹۲/۹۷٪ می‌باشد. در مقاله [۱۰] اثر استفاده از طبقه‌بندی درخت تصمیم جهت استخراج ویژگی‌های زمان‌بر روی سیگنال‌های الکتروکاردیوگرام با مقادیر ضربان قلب بررسی شده است. پایگاه داده آریتمی شامل ضبط تقریباً ۳۰ دقیقه ضربان قلب از ۴۷ بیمار است و از شش نوع ضربان قلب استفاده شده است که شامل ریتم طبیعی، طبقه‌بندی بلوک شاخه چپ، طبقه‌بندی بلوک شاخه راست، ضربان زودرس، انقباض زودرس بطنی و ضربان هنگام حرکت می‌باشد. ضربان قلب با نرخ‌های مختلف در این مطالعه مورد استفاده قرار می‌گیرد و طبقه‌بندی آریتمی ضربان قلب با استفاده از طبقه‌بندی درخت تصمیم مورد بررسی قرار می‌گیرد. ۳۷ درصد داده‌های استفاده شده به‌عنوان داده مخرب حذف شدند و داده‌های باقی‌مانده با استفاده از روش اعتبارسنجی ۱۰ بخشی جهت آموزش و تست سیستم مورد استفاده قرار گرفتند. دقت طبقه‌بندی درخت تصمیم ۹۹/۵۱٪ به‌دست آمده است [۱۰]. آریتمی قلب فعالیت‌های نامنظم قلب می‌باشد که توسط آلکویک و همکاران<sup>۶</sup> [۱۱] مورد بررسی قرار گرفته است. در این تحقیق طبقه‌بندی جنگل تصادفی برای طبقه‌بندی سیگنال ضربان قلب و تبدیل مویجک گسسته برای تشخیص آریتمی قلب به کار برده شده است. پایگاه داده استفاده شده شامل ۴۷ پرونده مربوط به سال‌های ۱۹۷۵ تا ۱۹۷۹ می‌باشد که ۲۵ نفر آن‌ها مردان در رده سنی ۳۲ تا ۸۹ سال بودند و ۲۲ نفر از آن‌ها خانم‌ها در رده سنی ۲۳ تا ۸۹ سال بودند. موارد بررسی شده در داده‌ها شامل ضربان زودرس، بلوک شاخه سمت چپ، بلوک شاخه سمت راست، انقباضات زودرس دهلیز و انقباضات زودرس بلوک

1. Jadhav
2. Martis
3. Yao
4. Kelwade
5. SLPBD
6. Alickovic et al.

می‌باشد. جهت اعتبارسنجی روش پیشنهادی از اعتبارسنجی ۱۰ بخشی استفاده شده است که در نتایج به دست آمده برای سیستم پیشنهادی مؤثر می‌باشد. طبقه‌بندی جنگل تصادفی با استفاده از تحلیل منحنی ROC<sup>۱</sup> به دقت ۹۹/۳۱٪ رسیده است. نتایج به دست آمده نشان می‌دهد که سیستم پیشنهادی دارای ظرفیت قابل اعتمادی برای طبقه‌بندی سیگنال‌های الکتروکاردیوگرام و کمک به پزشکان برای تشخیص دقیق اختلالات قلب است. استفاده از طبقه‌بندی جنگل تصادفی نسبت به روش‌های تصمیم‌گیری برای طبقه‌بندی سیگنال الکتروکاردیوگرام کارا تر می‌باشد و دارای نتایج بهتری است [۱۱]. هانگ و همکاران<sup>۲</sup> [۱۲] یک شبکه حسگر بی‌سیم برای تشخیص ضربان قلب و تغییرات آن ارائه شده است و همچنین یک مدل فازی برای تشخیص ضربان قلب طبیعی و آریتمی طراحی شده است. در این مطالعه از پایگاه داده آریتمی استفاده شده است و ویژگی‌های آریتمی و انواع ضربان قلب مربوط به آن بررسی شده است. نمونه برداری نرخ داده‌ها شامل ۳۶۰ هرتز در مدت ۳۰ دقیقه است. داده‌های آریتمی تشکیل شده از پارامترهای بلوک شاخه سمت چپ، بلوک شاخه راست، انقباضات زودرس بطنی، نارسایی انقباضات دهلیزی و ضربان زودرس است. این مطالعه جهت انتخاب ویژگی‌هایی است که برای تشخیص آریتمی ضروری می‌باشد. ویژگی‌های انتخاب شده به عنوان متغیرهای ورودی در فازی استفاده می‌شود. هر فایل داده در پایگاه داده یک شماره شاخص منحصر به فرد دارد که نشان دهنده نوع ضربان قلب است. سیستم پیشنهادی جهت تشخیص آریتمی قلب به دقت ۹۵/۴۲٪ رسیده است [۱۲]. پلات<sup>۳</sup> از [۱۳] سیستم تشخیص ایمنی مصنوعی و یادگیری ماشین جهت طبقه‌بندی داده‌های آریتمی استفاده شده است. مجموعه داده‌های آریتمی دارای ۲۷۹ ویژگی است که ۲۰۶ ویژگی خطی هستند و بقیه اسمی هستند. به طور کلی ۴۵۲ نمونه مورد بررسی قرار گرفته است. ۷۰٪ مجموعه داده‌های استفاده شده جهت آموزش سیستم و ۳۰٪ داده‌ها جهت تست سیستم استفاده شده‌اند. الگوریتم طبقه‌بندی ایمنی یک منبع محدود الگوریتم یادگیری با نظارت است. ابتدا تمام داده‌ها برای اطمینان از اینکه فاصله اقلیدس بین دو داده در فاصله [۰-۱] است بررسی می‌شوند، سپس الگوریتم شروع به تکرار برای آموزش می‌کند. در روش وزن‌گیری فازی، هر ویژگی با توجه به ارزش قدیمی آن وزن جدیدی می‌گیرد. تابع عضویت سیستم مثلثی انتخاب شده است. یکی از مزایای روش ارائه شده این است که لازم نیست تنظیمات مناسب برای طبقه‌بندی را بدانیم، به طور اتوماتیک این کار انجام می‌شود. دقت طبقه‌بندی ۷۶/۹۲٪ به دست آمده است [۱۳]. در مطالعه اچاریا<sup>۴</sup> [۱۴]، یک ابزار جدید برای تمایز خودکار آریتمی تهاجمی و غیرتهاجمی پیشنهاد شده است و از یک شبکه عصبی مصنوعی استفاده شده است. سیگنال‌های الکتروکاردیوگرام مورد استفاده در این مطالعه از طریق سه پایگاه داده جمع‌آوری شده است. سیگنال‌های الکتروکاردیوگرام از پایگاه داده در نرخ ۳۶۰ هرتز به دست آمده است در حالی که سیگنال‌های الکتروکاردیوگرام در دو پایگاه داده دیگر با سرعت ۲۵۰ هرتز نمونه‌برداری شدند. داده‌های استفاده شده شامل ۵۰۰ نمونه است. جهت اعتبارسنجی سیستم از روش اعتبارسنجی ۱۰ بخشی استفاده شده است و حداکثر دقت، حساسیت و خاصیت به دست آمده مقادیر ۹۳/۱۸٪، ۹۵/۳۲٪ و ۹۱/۰۴٪ می‌باشد. عملکرد بالای سیستم پیشنهادی می‌تواند در تشخیص آریتمی قلبی مؤثر باشد و احتمال زنده ماندن را افزایش دهد [۱۴].

زارعی و همکاران<sup>۵</sup> [۱۵] به منظور تشخیص و تقطیع خودکار تومورهای مغزی، یک چارچوب مبتنی بر یادگیری ماشین و پردازش تصویر روی مجموعه داده استاندارد BraTS ارائه کرد. روش کار در این پژوهش شامل سه گام اصلی پیش‌پردازش تصاویر، استخراج ویژگی‌های چندمقیاسی و به کارگیری یک مدل طبقه‌بندی یادگیری ماشین بود.

1. Receiver operating characteristic (ROC)
2. Huang et al.
3. Polat
4. Acharya
5. Zarei et al.

این ساختار الگوریتمی موفق شد در تقطیع تومورها به دقت بالای ۹۳/۶۲٪ (Dice Score) و خطای میانگین مربعات (MSE) بسیار پایین ۰/۸۵۰ برسد که نشان‌دهنده کارایی بالای این روش در کاربردهای بالینی است. در پژوهش دیدولو و همکاران<sup>۱</sup> [۱۶]، یک روش تشخیص آریتمی قلبی با استفاده از رویکرد یادگیری عمیق و نمایش زمان-فرکانس سیگنال‌های الکتروکاردیوگرام ارائه شده است. در این مطالعه، سیگنال‌های الکتروکاردیوگرام از پایگاه‌های داده MIT-BIH Normal Sinus Rhythm، MIT-BIH و BIDMC Congestive Heart Failure استخراج و پیش‌پردازش می‌شوند. هر رکورد به ۲۰ بخش مساوی تقسیم شده و به تصاویر دو بُعدی زمان-فرکانس با استفاده از تبدیل موجک مورز تعمیم‌یافته تبدیل می‌گردد. مدل پیشنهادی بر پایه ResNet-50 با یادگیری انتقال تنظیم شده است و شامل پارامترهایی مانند نرخ یادگیری ۰/۰۰۰۱، بهینه‌ساز ADAM و ۱۵ دوره آموزشی می‌باشد. داده‌ها به نسبت ۸۰٪ آموزش/اعتبارسنجی و ۲۰٪ تست تقسیم شده‌اند. سیستم پیشنهادی برای طبقه‌بندی سه کلاس (آریتمی، نارسایی احتقانی قلب و ریتم سینوسی طبیعی) به دقت کلی ۹۹/۲٪، حساسیت متوسط ۹۹/۲٪، ویژگی متوسط ۹۹/۶٪ و F-measure متوسط ۹۹/۲٪ دست یافته است [۱۶].

راشد و همکاران<sup>۲</sup> [۱۷]، یک بررسی جامع بر تشخیص آریتمی با استفاده از یادگیری عمیق بر روی سیگنال‌های الکتروکاردیوگرام انجام شده است. این مطالعه ۳۰ مقاله از پایگاه‌های PubMed، Web of Science و Scopus را با استفاده از کلمات کلیدی مانند «یادگیری عمیق» و «تشخیص آریتمی» تحلیل کرده و بر مدل‌های CNN<sup>۳</sup>، RNN<sup>۴</sup> و هیبریدی تمرکز دارد. پیش‌پردازش شامل تبدیل موجک، فیلترینگ و افزایش داده با SMOTEENN<sup>۵</sup> است. ارزیابی براساس معیارهایی مانند دقت و F1-score انجام شده و از اعتبارسنجی متقابل k-fold استفاده می‌شود. نتایج نشان‌دهنده دقت‌های بالا تا ۹۹/۹۳٪ (با ResNet-50 روی MIT-BIH) و F1-score تا ۹۹/۵۷٪ است. چالش‌هایی مانند ناهمگونی داده‌ها و بیش‌برازش برجسته شده و جهت‌گیری‌های آینده شامل پیاده‌سازی واقعی زمان و داده‌های متنوع پیشنهاد شده است [۱۷]. بای<sup>۶</sup> [۱۸] یک شبکه یادگیری عمیق هیبریدی برای تشخیص خودکار آریتمی قلبی براساس الکتروکاردیوگرام ۱۲-لیدی ارائه می‌دهد. مدل CBGM شامل CNN برای استخراج ویژگی‌های فضایی، BiGRU برای وابستگی‌های زمانی و مکانیسم توجه چندسرها برای تمرکز بر ویژگی‌های کلیدی است. پیش‌پردازش با فیلتر کالمن و تبدیل موجک برای حذف نویز و تشخیص R-peak انجام می‌شود. از پایگاه‌های MIT-BIH (۴۸ رکورد، ۳۶۰ هرتز) و PTB (۲۹۰ رکورد، ۱۰۰۰ هرتز) استفاده شده و داده‌ها با نرخ یادگیری ۰/۰۰۱ و اندازه دسته ۱۲۸ در PyTorch آموزش دیده‌اند. برای طبقه‌بندی پنج کلاس (ریتم سینوسی طبیعی، انقباض زودرس دهلیزی، انقباض زودرس بطنی، بلوک شاخه چپ و راست)، دقت متوسط ۹۹/۴۱٪، دقت ۹۹/۱۵٪، F1-score ۹۹/۲۱٪ و ویژگی ۹۹/۶۸٪ روی MIT-BIH به دست آمده است [۱۸]. انصاری<sup>۷</sup> [۱۹]، طی یک بررسی بر پیشرفت‌های یادگیری عمیق برای تشخیص و طبقه‌بندی آریتمی الکتروکاردیوگرام از سال ۲۰۱۷ تا ۲۰۲۳ ارائه شده است. ۷۸ مطالعه با دقت  $\leq 96\%$  از Google Scholar، PubMed و Scopus انتخاب شده و مدل‌های CNN، RNN/LSTM/GRU، INCARTDB، MIT-BIH، ترانسفورمرها و هیبریدی دسته‌بندی شده‌اند. خط لوله شامل انتخاب پایگاه داده (مانند MIT-BIH، INCARTDB)، پیش‌پردازش (حذف نویز، تقسیم‌بندی)، استخراج ویژگی و طبقه‌بندی با اعتبارسنجی ۱۰-بخشی است. نتایج نشان‌دهنده برتری مدل‌های هیبریدی با دقت  $< 96\%$  برای ۵-۱۵ کلاس آریتمی است. چالش‌هایی مانند عدم تعادل داده

1. Daydulo et al.

2. Rashed et al.

3. convolutional neural network

4. recurrent neural network

5. synthetic minority over-sampling technique

6. Bai

7. Ansari

و هزینه محاسباتی برجسته و جهت‌گیری‌های آینده شامل مدل‌های تفسیرپذیر و یادگیری تقویتی پیشنهاد شده است [۱۹]. سنگتا [۲۰]، یک روش تشخیص آریتمی قلبی با استفاده از شبکه عصبی مصنوعی برای دستگاه پوشیدنی «نظارت بر ناهنجاری قلبی» پیشنهاد شده است. الگوریتم Levenberg-Marquardt ANN به‌عنوان مدل اصلی انتخاب شده و با شش مدل دیگر (از جمله Kernelized SVC با PCA) مقایسه می‌شود. تمرکز بر کارایی توان و هزینه است و ادغام با سیستم‌های جاسازی‌شده آفلاین یا IoT بررسی می‌گردد. از پایگاه داده MIT-BIH استفاده شده و مدل در متلب شبیه‌سازی شده است. Kernelized SVC با PCA به‌عنوان جایگزین با دقت تست بالا شناسایی شده و مدل پیشنهادی برای کاربردهای پوشیدنی عملی و قابل اعتماد ارزیابی شده است [۲۰].

## روش

یک سیستم هوشمند تشخیص پزشکی باید دارای ورودی و خروجی باشد که هر ورودی و خروجی، دارای یک سری ویژگی‌ها باشند. در ابتدا باید نرمال کردن داده‌ها صورت گیرد که برای این کار، خوشبختانه مجموعه داده ای که استفاده می‌شود، به‌صورت نرمال شده است و فقط نیاز است مرحله استخراج ویژگی‌ها انجام شود که این کار با الگوریتم بهینه‌سازی خفاش صورت می‌پذیرد. قابل ذکر است که بهترین ویژگی‌ها در دور تکرارهای این الگوریتم مشخص و ابتدا عملیات کاهش ابعاد در آن صورت می‌گیرد و سپس این ویژگی‌ها انتخاب و در نهایت استخراج می‌شوند و به‌عنوان ورودی به شبکه عصبی کانولوشن برای تشخیص و طبقه‌بندی داده می‌شود. در ابتدا مدل‌سازی عملیات استخراج ویژگی با الگوریتم بهینه‌سازی خفاش بیان می‌گردد.

هر خفاش با سرعت  $v_i^t$  و موقعیت  $x_i^t$  در دوره تکرار  $t$  در یک فضای جست‌وجو یا راه‌حل  $d$  بُعدی مشارکت دارد. در میان تمام خفاش‌ها، یک سری راه‌حل  $x_*$  که بهترین حالت جاری هستند، وجود دارد. بنابراین سه قانون یاد شده در [۱۶] منجر به ساخت سه معادله الی ۳ برای  $x_i^t$  و  $v_i^t$  خواهد شد.

$$f_i = f_{min} + (f_{max} - f_{min})\beta \quad (۱)$$

$$v_i^t = v_i^{t-1} + (x_i^{t-1} - x_*)f_i \quad (۲)$$

$$x_i^t = x_i^{t-1} + v_i^t \quad (۳)$$

که  $\beta \in [0,1]$  یک بردار تصادفی گرفته شده از یک توزیع یکنواخت است. همان‌طور که قبلاً ذکر شد، می‌توان از طول موج‌ها یا فرکانس‌ها برای پیاده‌سازی استفاده کرد.

بدین صورت که با استفاده از  $f_{min}=0$  و  $f_{max} = O(1)$  که بستگی به اندازه دامنه مسئله دارد، به فرموله کردن برنامه مورد نظر پرداخت. در ابتدا به هر خفاش به‌صورت تصادفی از فرکانسی به‌صورت یکنواخت اختصاص می‌یابد که از  $[f_{min}, f_{max}]$  ناشی می‌شود. به این دلیل، الگوریتم خفاش می‌تواند به‌عنوان الگوریتمی جهت تنظیم فرکانس به‌منظور ارائه یک ترکیب متعادل اکتشاف و بهره‌برداری، مورد استفاده واقع شود. بلندی صدا و نرخ انتشار پالس می‌تواند به ایجاد یک مکانیزم برای کنترل خودکار و هدف‌گیری خودکار در یک ناحیه، جواب‌های بهینه‌ای را به‌دست آورند.

به‌منظور فراهم کردن مکانیزم مؤثری برای کنترل اکتشاف و بهره‌برداری و درصورت لزوم تبدیل به مرحله بهره‌برداری به‌صورت مستقیم، بایستی تغییرات بلندی صدا  $A_i$  و نرخ پالس منتشر شده  $r_i$  در زمان تکرارها را به‌دست آورد. از آنجا که بلندی صدا معمولاً یک بار کاهش می‌یابد، یک خفاش به پیدا کردن طعمه می‌پردازد. درحالی که وقتی نرخ انتشار پالس افزایش می‌یابد، بلندی صدا می‌تواند به‌عنوان هر مقداری که ساده‌تر باشد بین  $A_{min}$  و  $A_{max}$

با فرض  $A_{min} = 0$ ، در نظر گرفته شود که به معنی این است که یک خفاش فقط طعمه را پیدا کرده و به صورت موقت دست از انتشار صدا برداشته است. با این فرضیات، رابطه (۴) خواهد بود.

$$A_i^{t+1} = \alpha A_i^t, \quad r_i^{t+1} = r_i^0 [1 - \exp(-\gamma t)] \quad (4)$$

که در رابطه (۴)،  $\gamma$  و  $\alpha$  مقادیری ثابت می‌باشند. در اصل،  $\alpha$  شباهت فراوانی با معیار خنک‌سازی در الگوریتم تبرید شبیه‌سازی شده دارد که باید آن را در بازه‌ای مشخص قرار دارند. دلیل شباهت آن به خاطر حالت آن است که در بازه‌ای قرار دارد که مقدار  $\alpha$  در الگوریتم تبرید شبیه‌سازی شده نیز در همان بازه قرار دارد. برای هر  $0 < \alpha < 1$  و  $0 > \gamma$  وجود دارد.

$$A_i^t \rightarrow 0, \quad r_i^t \rightarrow r_i^0, \quad \text{as } t \rightarrow \infty \quad (5)$$

در ساده‌ترین حالت، می‌توان  $\alpha = \gamma$  را در نظر گرفت و از مقدار  $\alpha = \gamma = 0.9$  الی  $0.98$  در شبیه‌سازی‌ها استفاده کرد. به منظور بهبود تنوع از راه‌حل‌های ممکن، روشی جهت حرکات تصادفی در الگوریتم بهینه‌سازی خفاش برای استخراج ویژگی‌ها از سیگنال‌های الکتروکاردیوگرام وجود دارد. در ابتدا یک راه‌حل از بین بهترین جواب‌ها انتخاب می‌شود و سپس حرکت تصادفی جهت تولید یک راه‌حل جدید برای هر خفاش که شرط اگر  $random\ motion > r_i$  را پذیرفته باشد، طبق رابطه (۶) خواهد بود.

$$x_{new} = x_{old} + \varepsilon \bar{A}(t) \quad (6)$$

که  $\bar{A}(t)$  میانگین بلندی صدای همه خفاش در زمان  $t$  است و  $\varepsilon \in [-1.1]$  تلاش بر مستقیم‌سازی و قدرت حرکت تصادفی دارد. برای هر تکرار الگوریتم، بلندی صدا  $A_i$  و نرخ انتشار پالس  $r_i$  به صورت رابطه (۷) و (۸) به روزرسانی می‌شود.

$$A_i(t+1) = \alpha A_i(t) \quad (7)$$

$$r_i(t+1) = r_i(0) [1 - \exp(\gamma t)] \quad (8)$$

هر موقعیت خفاش در فضای جست‌وجو به نمایش زیرمجموعه‌ای از ویژگی‌هایی می‌پردازد که نشان می‌دهد. بنابراین، برای هر کدام از آن‌ها، یک مقدار برازش برای هر خفاش، لحاظ می‌شود که در دور تکرارهای مختلف، بهترین خفاش برازش شده، تعیین می‌گردد. نکته حائز اهمیت این است که مجموعه آموزشی و ارزیابی در خفاش‌ها از زمانی که هر کدامشان یک مجموعه ویژگی را مشخص کنند، ممکن است متفاوت باشد. در ابتدا جمعیت آغازین خفاش‌ها در نظر گرفته می‌شود. سپس موقعیت خفاش با مقدار انتخابی تصادفی که به بررسی انتخاب ویژگی و یا انتخاب نکردن آن می‌پردازد، آغاز می‌شود. سپس مجموعه جدید آموزش و ارزیابی با ویژگی‌های انتخاب شده شروع و سپس به روزرسانی مقدار برازش برای هر خفاش انجام می‌شود. علاوه بر این، بلندی صدا  $A_i$  و نرخ انتشار پالس  $r_i$  با این شرط که راه‌حل جدید مورد پذیرش باشد، به روزرسانی می‌شود. خروجی حداکثر تابع به عنوان یک شاخص در نظر گرفته می‌شود و مقدار برازش خفاش منجر به حداکثر رسانی تابع برازش می‌شود. موقعیت و سرعت می‌بایست به روزرسانی شوند که با توجه به بیشترین مقدار تابع برازش به دست آمده برای هر خفاش، این کار انجام می‌شود. قابل ذکر است که تابع برازش الگوریتم بهینه‌سازی خفاش، رسیدن به شرط خاتمه برای استخراج بهترین ویژگی‌ها و تولید نسل‌های جدید است که به عنوان ورودی شبکه عصبی کانولوشن برشمرده می‌شود. با در نظر گرفتن یک سیستم تشخیص بهبود بیماری قلبی آریتمی با مدل فضای حالت طبق رابطه (۹)، بردار تبدیلات سیگنالی به صورت ذیل است.

$$u(t) = -Kx(t) \quad (9)$$

به منظور تعیین ورودی‌های بهینه در زمانی که بهینه‌سازی متغیرهای حالت در یک لحظه انجام می‌شود، تابع برازش الگوریتم بهینه‌سازی خفاش که به نام تابع شاخص کارایی درجه دوم نیز شناخته می‌شود، به منظور کمینه‌سازی به صورت رابطه (۱۰) استفاده می‌شود.

$$J = \frac{1}{2} \int (x^T Q x + u^T R u) dt \quad (10)$$

که طبق رابطه (۱۰)،  $Q$  ماتریس نیمه مثبت متقارن قطعی و  $R$  ماتریس مثبت متقارن قطعی است. ماتریس‌های وزن  $Q$  و  $R$  به منظور استخراج ویژگی هر حالت مؤثر مبتنی بر بهترین ویژگی‌ها از سیگنال الکتروکاردیوگرام، انتخاب می‌شوند. ماتریس گین<sup>۱</sup> بردار استخراج‌کننده ویژگی‌های بهینه براساس حالت خفاش‌ها، به صورت رابطه (۱۱) محاسبه می‌شود.

$$K = T^{-1}(T^T)^{-1}B^T P = R^{-1}B^T P \quad (11)$$

بنابراین براساس رابطه (۱۱) معادله استخراج‌کننده ویژگی‌های بهینه براساس حالت خودمشتابه سیگنال‌ها و استخراج آن‌ها با الگوریتم بهینه‌سازی خفاش به صورت رابطه (۱۲) تبدیل می‌شود.

$$A^T P + PA - PBR^{-1}B^T P + Q = 0 \quad (12)$$

اگر یک ماتریس  $P$  مثبت قطعی بتواند توسط معادله ریکارتی<sup>۲</sup> محاسبه شود، آن‌گاه سیگنال‌های تشخیص بیماری آریتمی به صورت رابطه (۱۳) مقاوم خواهد بود.

$$A^T P + PA - PBR^{-1}B^T P + Q = 0 \quad (13)$$

براساس یک سری شروط خاص، مدل استخراج‌کننده ویژگی‌ها با الگوریتم بهینه‌سازی خفاش، می‌تواند با استفاده از معادله ریکارتی مانند معادله (۱۳)، طراحی شود که بدون تغییر ماتریس حرکتی و حالت به منظور یافتن ماتریس گین بهینه، مورد استفاده واقع می‌گردد. فیلتر بهینه نیز می‌تواند با در نظر گرفتن اینکه چند حالت نامشخص وجود دارد، تعیین گردد. برای یک سیگنال قلبی بدون اضافه کردن یک انتگرال، می‌توان از ماتریس  $A$  و  $B$  که از قبل مشخص شده‌اند، با یکدیگر جهت کنترل استفاده نمود و ماتریس‌های وزن حالت  $Q$  و  $R$  به منظور یافتن ماتریس گین بهینه یا  $K$  را می‌دهد که اجازه یافتن ورودی استخراج به صورت  $u = -kx(t)$  است. معادلات سیستم با استفاده از رویکرد اولر<sup>۳</sup>، گسسته شده است. در ابتدا، مدل تبدیل سیگنال‌ها بدون تأثیر بر اختلالات در سیگنال ورودی، مورد سنجش و ارزیابی قرار گرفت و در ادامه، پاسخ سیستم جهت کاهش ابعاد برای آموزش دهنده تحت شرایط اختلالات در الگوریتم بهینه‌سازی خفاش، بررسی شد.

در ادامه قرار است که از شبکه عصبی کانولوشن به عنوان تکنیک یادگیری عمیق برای تشخیص و طبقه‌بندی آریتمی قلبی استفاده شود. ویژگی‌ها به صورت یک ماتریس  $s$  خواهند بود که شامل فرکانس‌های نسبی با دو سیگنال می‌باشند که یکی با ارزش سطح خاکستری یعنی  $i$  و دیگری با ارزش  $j$  که با فاصله  $d$  و با زاویه معین  $\theta$  که در سیگنال ظاهر می‌شود، از یکدیگر جدا شده‌اند. با در نظر گرفتن پنجره سیگنال ورودی به صورت  $W(x, y, c)$  برای هر مقدار جداگانه  $d$  و  $\theta$ ، ماتریس ورودی‌ها به صورت هم‌رخدادی به صورت  $s(i, j, d, \theta)$  برای شبکه عصبی کانولوشن و تنظیمات کلی آن به شکل ذیل تعریف می‌شود:

۱. یک ورودی در ماتریس  $s$  شامل تعداد دفعاتی است که سطح خاکستری  $i$  به سطح خاکستری  $j$  متمایل می‌شود، به طوری که  $W(x_1, y_1) = i$  و  $W(x_2, y_2) = j$  باشد و رابطه  $(x_2, y_2) = (x_1, y_1) + (d \cos \theta, d \sin \theta)$  برقرار باشد.

1. Gain matrix  
2. Ricatti equation  
3. Euler

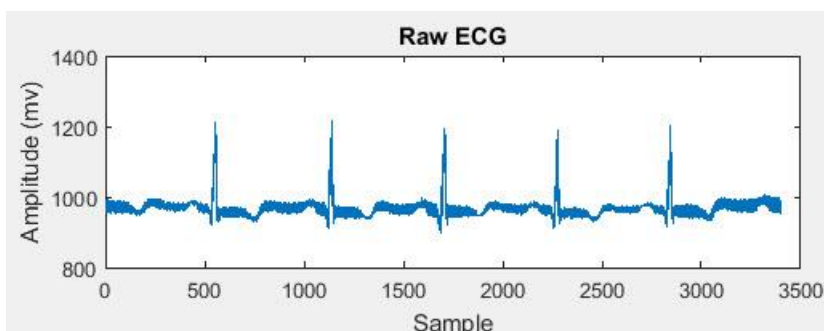
۲. ویژگی‌های حاصل از الگوریتم بهینه‌سازی خفاش (یا الگوریتم ژنتیک و تفاضل تکاملی) به‌عنوان ورودی‌ها در لایه ورودی و نرون‌های شبکه عصبی کانولوشن قرار می‌گیرند.
۳. شبکه عصبی کانولوشن در لایه پنهان یا میانی خود، دارای سه لایه می‌باشد که به ترتیب شامل لایه پیچش، لایه تماماً متصل و لایه پولینگ است.
۴. ورودی شبکه عصبی در نرون‌ها و لایه ورودی، به‌ازای ویژگی‌های استخراج شده می‌باشد.
۵. در لایه پیچش، یک فیلتر بایستی استفاده شود که وزن‌ها در آن مقداردهی می‌شوند و به‌صورت  $w[0] * x[0] + w[1] * x[1] + w[2] * x[2]$  قابل ذکر است که این فیلتر به‌صورت گشادگی یا Dilation است. وزن اولیه که محتوای فیلتر است، به‌صورت یک ماتریس  $4 \times 4$  الی  $8 \times 8$  خواهد بود که به ابعاد ویژگی‌های استخراج شده، قابل تغییر در بازه نام برده است.
۶. تابع غیرخطی به‌عنوان تابع محرک که به لایه پیچش اعمال می‌شود، تابع زیگموئید است.
۷. حداکثر نرخ پولینگ در لایه پولینگ، به‌صورت ساده یا simple pooling استفاده شده است.
۸. آموزش در لایه‌های پنهان یا مخفی شبکه عصبی کانولوشن در یک دور تکرار مشخص انجام و در صورتی که کلاس‌های ویژگی‌ها مشخص شدند، طبقه‌بندی انجام و شرط خاتمه خواهد بود و در انتها، تشخیص آرتیمی قلبی از سیگنال الکتروکاردیوگرام مشخص می‌گردد.

#### جدول ۱. مراحل و روابط ریاضی در بخش روش‌شناسی پژوهش

فاز پژوهش	شماره رابطه ریاضی	تعریف کلی رابطه	کاربرد در پژوهش شما (تشخیص آرتیمی)
فاز ۱: مدل‌سازی حرکت و جست‌وجوی اولیه	(۱) الی (۳)	قوانین به‌روزرسانی سرعت (v) و موقعیت (x) خفاش‌ها در فضای d-بعدی.	شبیه‌سازی حرکت عامل‌های جست‌وجو برای یافتن بهترین ویژگی‌ها از سیگنال‌های قلب در فضای جست‌وجوی ویژگی‌ها.
فاز ۲: تنظیم پارامترهای آکوستیک	(۴) و (۵)	تعریف رفتار بلندی صدا (A) و نرخ انتشار پالس (r) با الهام از رفتار خفاش‌ها و مشابه معیار خنک‌سازی در تبرید شبیه‌سازی شده.	ایجاد مکانیزم گذار از مرحله اکتشاف (جست‌وجوی سراسری ویژگی‌ها) به مرحله بهره‌برداری (تمرکز روی ویژگی‌های دقیق‌تر).
فاز ۳: جست‌وجوی محلی و تولید راهکار جدید	(۶)	معادله حرکت تصادفی (Random Walk) در صورت پذیرش شرط.	تولید یک مجموعه ویژگی جدید و بهینه‌تر در اطراف بهترین ویژگی‌های یافت‌شده تا این لحظه (بهبود محلی راهکارها).
فاز ۴: کنترل پویای الگوریتم	(۷) و (۸)	به‌روزرسانی مقادیر بلندی صدا (At) و نرخ انتشار پالس (rt) در هر تکرار.	کنترل خودکار تعادل بین جست‌وجوی سراسری و محلی در حین اجرای الگوریتم برای جلوگیری از گیر افتادن در ویژگی‌های غیر بهینه.
فاز ۵: مدل‌سازی ریاضی استخراج ویژگی	(۱۱) و (۱۲)	تبدیل مدل استخراج ویژگی‌ها به یک فرم بهینه با در نظر گرفتن خاصیت خودمیشابهی (Self-similarity) سیگنال‌ها.	تطبیق مدل استخراج ویژگی با ساختار و ماهیت تکرارشونده و خودمیشابه سیگنال‌های قلبی.
فاز ۶: طراحی استخراج‌کننده مقاوم	(۱۳)	فرم گسسته‌شده معادله ریکاتی (Riccati Equation) برای محاسبه ماتریس مثبت قطعی.	طراحی نهایی یک فیلتر/گین بهینه و مقاوم روی سیگنال‌های ECG برای استخراج ویژگی‌هایی که در برابر نویز مقاوم بوده و آرتیمی را به درستی تشخیص دهند.


## یافته‌ها

در این پژوهش از مجموعه داده‌های سیگنال گفتار استفاده شده است. این مجموعه داده که به نام پایگاه داده چندسیگنالی خواب مؤسسه فناوری ماساچوست<sup>۱</sup> هم معروف است، مجموعه‌ای از سیگنال‌های فیزیولوژیک ضبط شده افراد واقعی در شرایط مختلف است. مجموعه داده دارای ۸۰ ساعت ارزش ۴ به ۶ و ضبط ۷ کانال پولیسوموگرافیک است که هر یک با سیگنال الکتروکاردیوگرام و حتی الکتروانسفالوگرام به منظور تعیین اهداف مختلف، استفاده شده‌اند. این پژوهش از سیگنال‌های الکتروکاردیوگرام به عنوان مجموعه داده‌های خود استفاده می‌کند. مجموعه داده‌ها به صورت نرمالیزه مورد استفاده واقع می‌شود که از بخش الکتروکاردیوگرام سیگنال‌های مجموعه داده نام برده، استفاده خواهد شد. سیگنال ورودی در شکل ۱ نشان داده می‌شود.



شکل ۱. سیگنال خام الکتروکاردیوگرام ورودی

به منظور رفع نویزهای احتمالی، از فیلتر میان‌گذر<sup>۲</sup> استفاده می‌شود. در واقع فرکانس سیگنال ورودی یعنی  $f$  به صورت  $1 < f < 13$  است. شکل ۲، سیگنال فیلترگذاری شده را نشان می‌دهد.

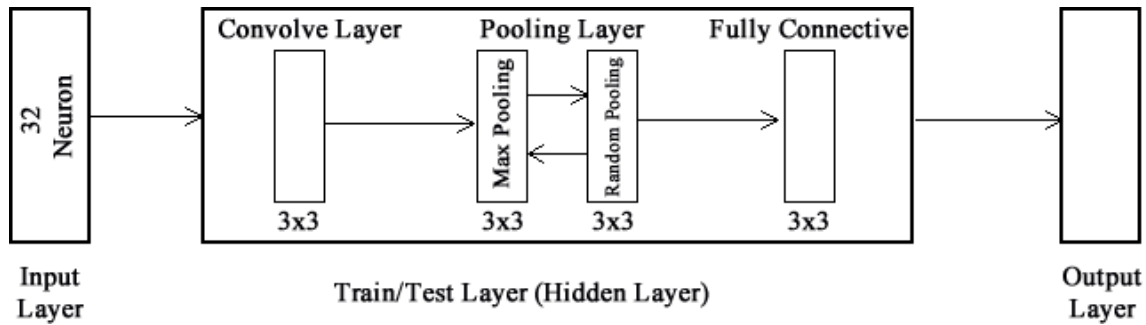


شکل ۲. سیگنال الکتروکاردیوگرام با فیلتر میان‌گذر به منظور رفع نویزهای احتمالی

از آنجا که رویکرد پیشنهادی ترکیبی از شبکه عصبی کانولوشن و الگوریتم بهینه‌سازی خفاش است نتایج آن مورد بررسی قرار می‌گیرد.

به صورت کلی، معماری شبکه عصبی کانولوشن بهینه شده مدنظر این تحقیق به صورت شکل ۳ است.

1. MIT-BIH polysomnographic  
2. Band-pass filter



شکل ۳. معماری شبکه عصبی کانولوشن مد نظر این تحقیق بعد از مدل نهایی

با توجه به شکل ۳ و معماری که برای شبکه عصبی کانولوشن در این تحقیق ارائه می‌شود، است تا لایه‌ها و تعداد آن‌ها مشخص گردد. در ابتدا ۳۲ نرون اولیه در لایه ورودی مد نظر قرار گرفته است که مجموع تمامی ویژگی‌های آریتمی قلبی را دربرمی‌گیرد. در بخش لایه پنهان که در شبکه عصبی کانولوشن دارای سه بخش اصلی یعنی پیچش، پولینگ و تماماً متصل است، تنظیماتی وجود دارد. مجموع این لایه‌ها، ۴ مورد در نظر گرفته شده است، به طوری که یک ماتریس پیچشی  $3 \times 3$  را ایجاد نماید. یعنی در هر کدام از ۴ لایه، یک ماتریس  $3 \times 3$  نیز وجود دارد. لایه پیچش، یک لایه است و لایه پولینگ، شامل دو لایه است که یک بخش آن به صورت بیشینه یا اصطلاحاً 'maxpol' مدنظر قرار گرفته شده است و بخش دیگر آن به صورت پولینگ تصادفی که بتواند آموزش هر کدام از ویژگی‌ها را نیز به صورت تصادفی در دسترس لایه تمام متصل که یک لایه است، انجام بدهد. مشاهده می‌شود که یک لایه پیچش، دو لایه پولینگ و یک لایه تماماً متصل وجود دارد و لایه خروجی، شامل هر گونه تحرک براساس تشخیص آریتمی قلبی است که در بخشی از سیگنال‌ها حاصل می‌گردد.

مسئله‌ای به نام مرکزیت یا centroid وجود دارد که در اصول طبقه‌بندی و حتی خوشه‌بندی، برای انجام کارهای تشخیص و ردیابی، مد نظر قرار می‌گیرد. در زمان پنجره‌یابی، اصولاً ساختار به صورت فرد است، یعنی  $3 \times 3$ ،  $5 \times 5$ ،  $7 \times 7$  و مواردی مانند این. دلیل این امر، آن است که یک خانه یا پیکسل در وسط قرار می‌گیرد و خانه‌های مجاور آن، تحلیل می‌گردند و آن پیکسل مرکزی، به عنوان مرکز یا centroid مد نظر قرار می‌گیرد. ساختار کلی و محاسبات پارامتریک در شبکه عصبی کانولوشن نیز به شرح ذیل است:

لایه ورودی چیزی برای یادگیری ندارد، در هسته اصلی، آنچه انجام می‌دهد فقط ارائه شکل داده ورودی است. بنابراین هیچ پارامتر قابل یادگیری در اینجا وجود ندارد. بنابراین تعداد پارامترها برابر صفر است.


لایه پیچش یا Conv، این جایی است که شبکه عصبی کانولوشن می‌آموزد، بنابراین مطمئناً ماتریس وزن خواهد داشت. برای محاسبه پارامترهای قابل یادگیری در اینجا، تنها کاری که باید انجام شود این است که فقط با اندازه عرض  $m$ ، ارتفاع  $n$  ضرب شود و برای همه این فیلترها حساب گردد. پارامترهای یک لایه پیچش یا Conv می‌تواند به صورت  $(m \times n) + 1$  باشد، به دلیل بایاس برای هر فیلتر یک واحد نیز اضافه شده است. همین عبارت را می‌توان به صورت زیر نوشت:

$$((\text{شکل عرض فیلتر} \times \text{شکل ارتفاع فیلتر} + 1) \times \text{تعداد فیلترها}).$$

لایه تجمیع یا pooling، این هیچ پارامتر قابل یادگیری ندارد، زیرا تنها کاری که انجام می‌دهد محاسبه یک عدد خاص است، بدون آنکه یادگیری انتشاری درگیر باشد. بنابراین تعداد پارامترهای آن برابر صفر است. دقت شود که در این لایه است که عملیات پنجره‌بندی تعیین می‌گردد. همین طور دو حالت در آن وجود دارد. یکی اینکه حد بالا

برابر ۱ و حد پایین برابر صفر باشند که در این صورت، مکانیزم به صورت تجمیع بیشینه Max pool است و در صورتی که حد بالا برابر صفر و حد پایین برابر یک باشد، مکانیزم آن به صورت تجمیع کمینه Min pool است. همین‌طور ساختاری تصادفی Random pool نیز در آن وجود دارد.

لایه تماماً متصل یا Fully Connective، این لایه قطعاً دارای پارامترهای قابل یادگیری است. از نظر واقعی، در مقایسه با سایر لایه‌ها، این دسته از لایه‌ها بیشترین تعداد پارامتر را دارند. زیرا هر نرون به هر نرون دیگر متصل است. بنابراین، چگونه می‌توان تعداد پارامترها را در اینجا محاسبه کرد؟ پاسخ روشن است، محصول تعداد نرون‌های موجود در لایه فعلی و تعداد نرون‌های لایه قبلی بایستی در نظر گرفته شود. بنابراین تعداد پارامترها در اینجا بدین شرح است: ((لایه فعلی  $\times$  n لایه قبلی  $+ 1$ ) که این به اضافه یک، برای بایاس است. در لایه اول آموزش، از تابع انتقال تانژانت زیگموئیدی یا tansig و در لایه دوم از تابع انتقال خطی یا purelin استفاده شده است. یک خروجی نیز در انتها وجود خواهد داشت. این توضیحات، در ساختار شکل ۴ واضح و مبرهن است.



شکل ۴. تنظیمات شبکه عصبی پرسپترون چندلایه

روش آموزش در شبکه عصبی کانولوشن نیز می‌بایست مشخص باشد. در اینجا از روش لونبرگ-مارکارد<sup>۱</sup> استفاده شده است که در MATLAB تحت عنوان trainlm شناخته می‌شود. کارایی شبکه عصبی نیز می‌بایست با یک روش در زمان آموزش، مورد سنجش و ارزیابی واقع شود که در اینجا از روش میانگین مربعات خطا<sup>۲</sup> استفاده شده است. نحوه محاسبات و مشتق‌گیری نیز به صورت MEX یعنی الحاقی در نظر گرفته شده است. این تنظیمات نیز در شکل ۵ مشخص است.

```

Training: Levenberg-Marquardt (trainlm)
Performance: Mean Squared Error (mse)
Calculations: MEX
    
```

شکل ۵. تنظیمات روش آموزش، سنجش کارایی و نحوه محاسبات و مشتق‌گیری شبکه عصبی کانولوشن

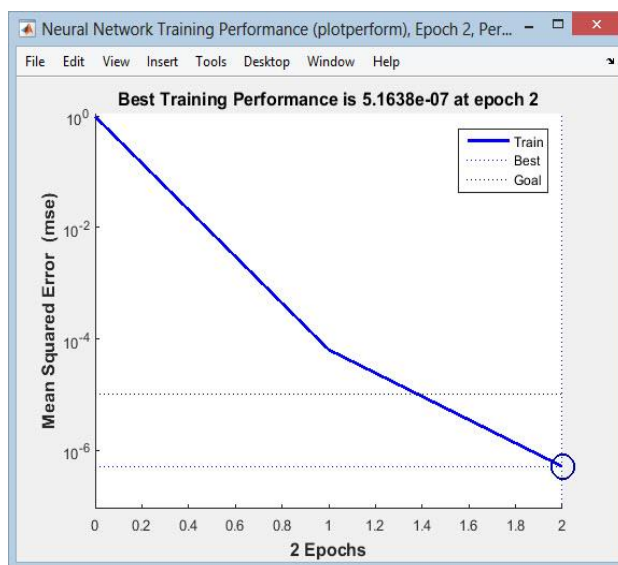
سایر تنظیمات شبکه عصبی کانولوشن نیز در شکل ۶ نشان داده شده است. تعداد دور تکرار ۴۰۵ دور، زمان شبیه‌سازی و آموزش ۴ دقیقه، نرخ کارایی به صورت واریانسی  $1/00e-05$ ، میزان گرادیان به صورت واریانسی  $1/00e-07$ ، نرخ جهش یا Mu به صورت واریانسی  $1/00e+10$  و اعتبارسنجی برابر ۶ می‌باشد.

1. levenberg-marquardt  
2. Mean square error (MSE)

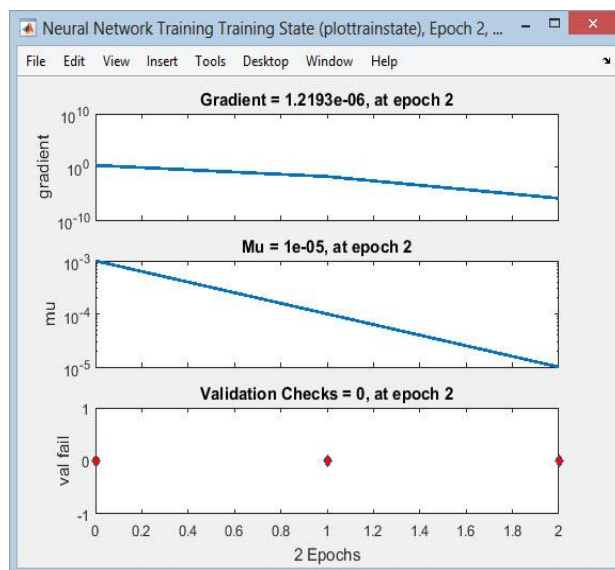
Epoch:	0	2 iterations	405
Time:	0:00:00	0:00:00	0:04:00
Performance:	0.972	5.16e-07	1.00e-05
Gradient:	2.00	1.22e-06	1.00e-07
Mu:	0.00100	1.00e-05	1.00e+10
Validation Checks:	0	0	6

شکل ۶. سایر تنظیمات شبکه عصبی کانولوشن

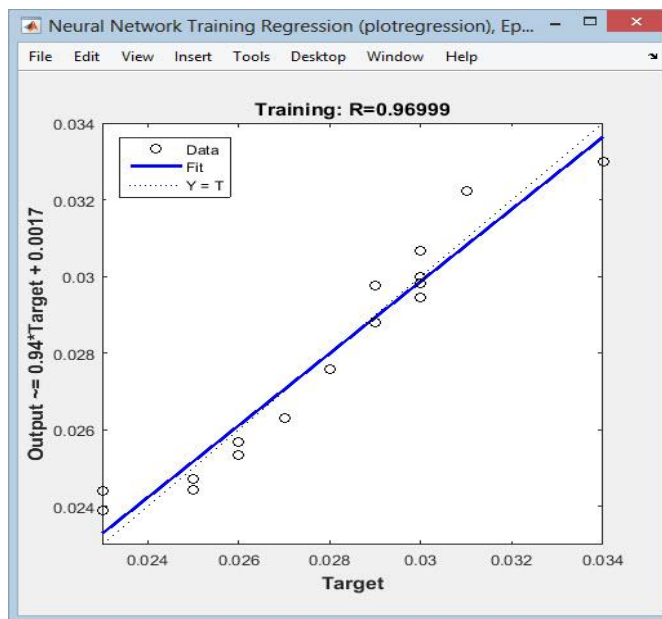
سه خروجی می‌توان از این شبکه عصبی را مشاهده نمود. در بخش Plot جعبه ابزار قرار دارد که شامل کارایی به صورت شکل ۷، شکل شرایط آموزشی به صورت شکل ۸ و رگرسیون به صورت شکل ۹ است.



شکل ۷. کارایی شبکه عصبی کانولوشن




شکل ۸. شرایط آموزشی شبکه عصبی کانولوشن




شکل ۹. رگرسیون شبکه عصبی کانولوشن

سپس حد میانه از سیگنال فیلترگذاری شده به منظور نرمال‌سازی بهتر خود سیگنال، انجام می‌گیرد که خروجی آن شکل ۱۰ است و هدف از این کار این بازتر کردن دامنه سیگنال است تا بتوان ویژگی‌های بیشتری از سیگنال را استخراج نمود. سپس نرمال‌سازی مربعی روی سیگنال انجام می‌شود که مانند شکل ۱۱ است.




شکل ۱۰. حد میانه از سیگنال فیلترگذاری شده




شکل ۱۱. نرمال‌سازی مربعی سیگنال

در شکل ۱۱ دوباره به باز کردن دامنه سیگنال پرداخته می‌شود. ممکن است به جای حالت نرمال‌سازی مربعی از روش‌های دیگری چون فیلترهای تطبیقی<sup>۱</sup> مانند فیلترهای RMS، LMS و یا NLMS نیز استفاده شود که در بعضی از شرایط که نویز وجود داشته باشد، می‌توانند مؤثر واقع گردند. سپس نرمال‌سازی ثانویه انجام می‌شود که در شکل ۱۲ نشان داده شده است و در انتها از روش گشادگی سیگنال جهت باز شدن آن استفاده می‌شود که نتیجه در شکل ۱۳ مشخص است.

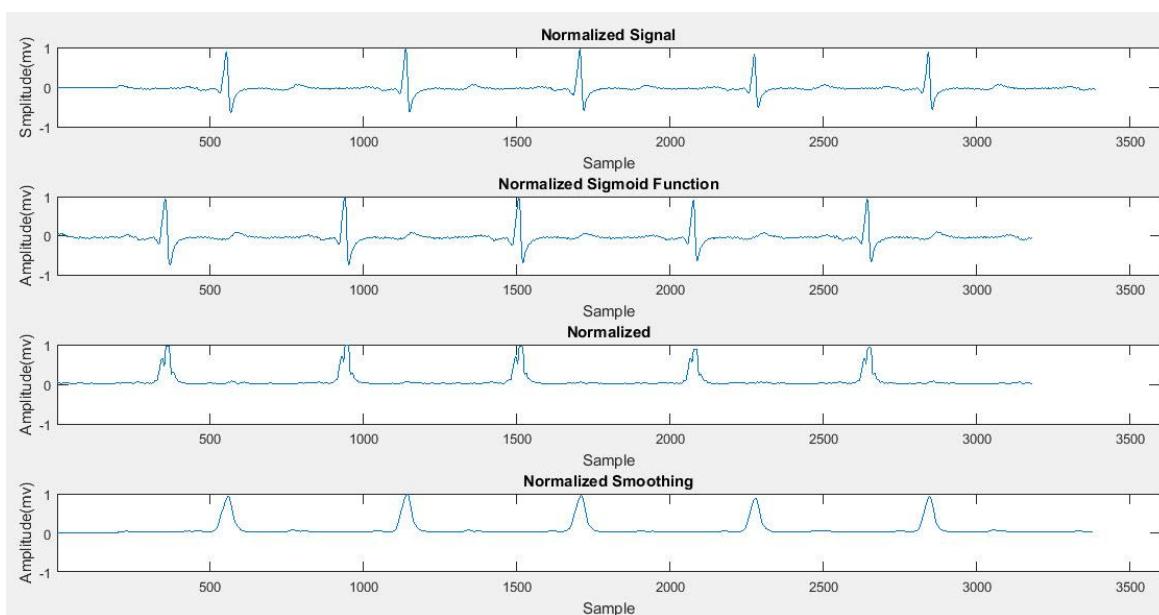


شکل ۱۲. نرمال‌سازی با هدف طبقه‌بندی



شکل ۱۳. گشادگی سیگنال

این گشادگی سیگنال باعث باز شدن کلی دامنه سیگنال بعد از چند مرحله کار می‌شود که در واقع دامنه‌های اصلی سیگنال (قله‌های سیگنال) کاملاً در شکل ۱۳ مشهود است. حال از عملیات پنجره‌سازی سیگنال<sup>۱</sup> به منظور پیدا کردن نقطه نمونه از سیگنال استفاده می‌شود که در این عمل از تابع زیگموئیدی<sup>۲</sup> استفاده شده است. سپس از میانگین متحرک<sup>۳</sup> جهت فیلترگذاری با ۲۱ نقطه نمونه از سیگنال کار را آغاز می‌کنیم. سپس مقادیر نرمال شده حاصل از طبقه‌بندی مبتنی بر شبکه عصبی کانولوشن را محاسبه می‌کنیم. در انتها از روش گشادگی سیگنال جهت بهبود طبقه‌بندی و باز شدن استفاده می‌شود که نتیجه در شکل ۱۴ مشخص است.

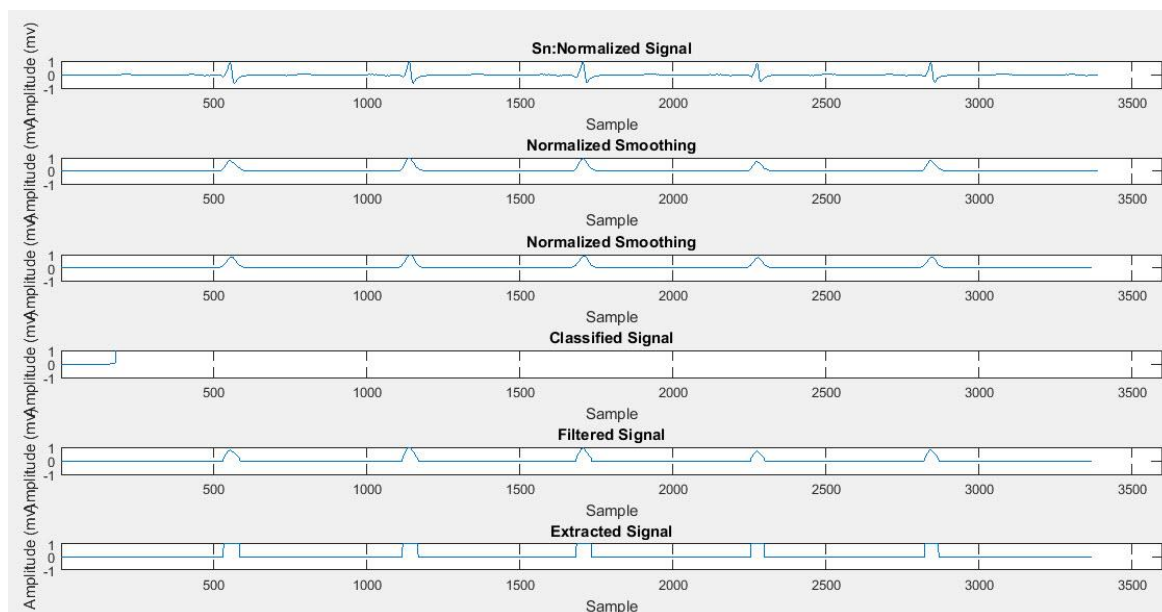


شکل ۱۴. نتایج عملیات نقطه نمونه

در اینجا عملیات استخراج ویژگی‌ها با الگوریتم خفاش در بخش آموزش شبکه عصبی کانولوشن و عملیات فیلترگذاری سیگنالی، آغاز می‌شود. الگوریتم خفاش با هدف کاهش ابعاد<sup>۴</sup>، انتخاب ویژگی<sup>۵</sup> و در نهایت استخراج

1. signal windowing
2. sigmoid function
3. average moving
4. dimension reduction
5. feature selection

ویژگی‌های<sup>۱</sup> سیگنال با فیلتر گرادینت<sup>۲</sup> که در واقع همان پنجره‌بندی است، شروع به کار می‌کند. در واقع سیگنال الکتروکاردیوگرام به فیلتر گرادینت ضرب می‌شود. عملیات در شکل ۱۵ نشان داده شده است.




شکل ۱۵. استخراج ویژگی مبتنی بر الگوریتم خفاش

حد میانه سیگنال نیز برابر ۵۶ می‌شود. حال الگوریتم خفاش با عملگرهایش وارد کار می‌شود که به تشخیص آریتمی قلبی می‌پردازد. در واقع عملیات قبلی این بار با استفاده از عملگرهای الگوریتم خفاش رخ می‌دهد. مقادیر عملگرهای الگوریتم خفاش و چند مقدار برای سیگنال‌ها در جدول ۲ ذکر شده است.

جدول ۲. مقادیر عملگرهای الگوریتم خفاش

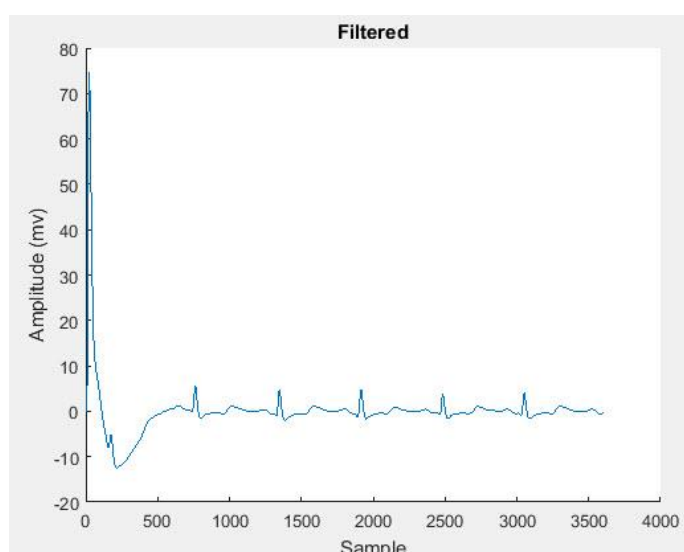
۳۶۰	جمعیت اولیه
۱۳	تعداد خفاش‌ها
۳۶۰ هرتز	فرکانس
۲	نرخ نمونه‌برداری
۰/۰۲	نرخ انعکاس
۰/۲۱	نرخ حرکت به سمت طعمه (شکار)
۱۰۰	تعداد دور تکرار

با توجه به مقادیر عملگرهای الگوریتم خفاش که به صورت تجربی و براساس توضیحات اولیه سازنده این الگوریتم تنظیم شده‌اند، در مجموع هدف کلی این الگوریتم، بهبود ویژگی‌های استخراج شده می‌باشد. بدین منظور، جمعیت اولیه خفاش در سیگنال به صورت شکل ۱۶ نمایش داده می‌شود.



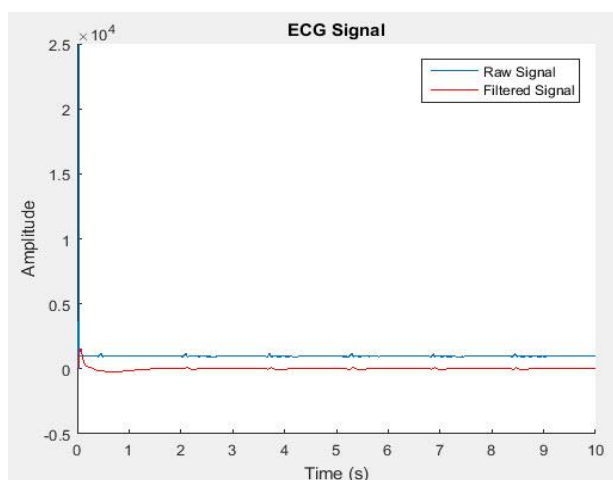
شکل ۱۶. جمعیت اولیه خفاش‌ها بر روی سیگنال

سپس تشخیص آریتمی و ویژگی‌های آن با توجه به دامنه و فیلترگذاری میانه از جمعیت اولیه سیگنال انجام می‌شود که خروجی آن شکل ۱۷ است.



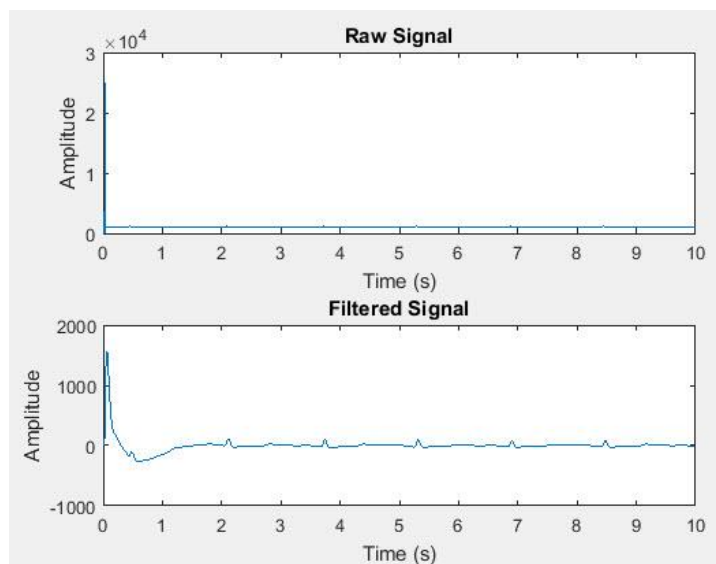
شکل ۱۷. تشخیص آریتمی با توجه به دامنه و فیلترگذاری میانه از جمعیت اولیه سیگنال

سپس سیگنال خام بعد از عملیات با شبکه عصبی کانولوشن به منظور طبقه‌بندی (بخش آبی رنگ) با سیگنالی که عملیات جهش روی آن رخ داده است و در واقع فیلترگذاری هم‌زمان با الگوریتم خفاش در فاز استخراج ویژگی‌ها است (بخش قرمز رنگ)، نمایش داده می‌شود که خروجی آن شکل ۱۸ است.



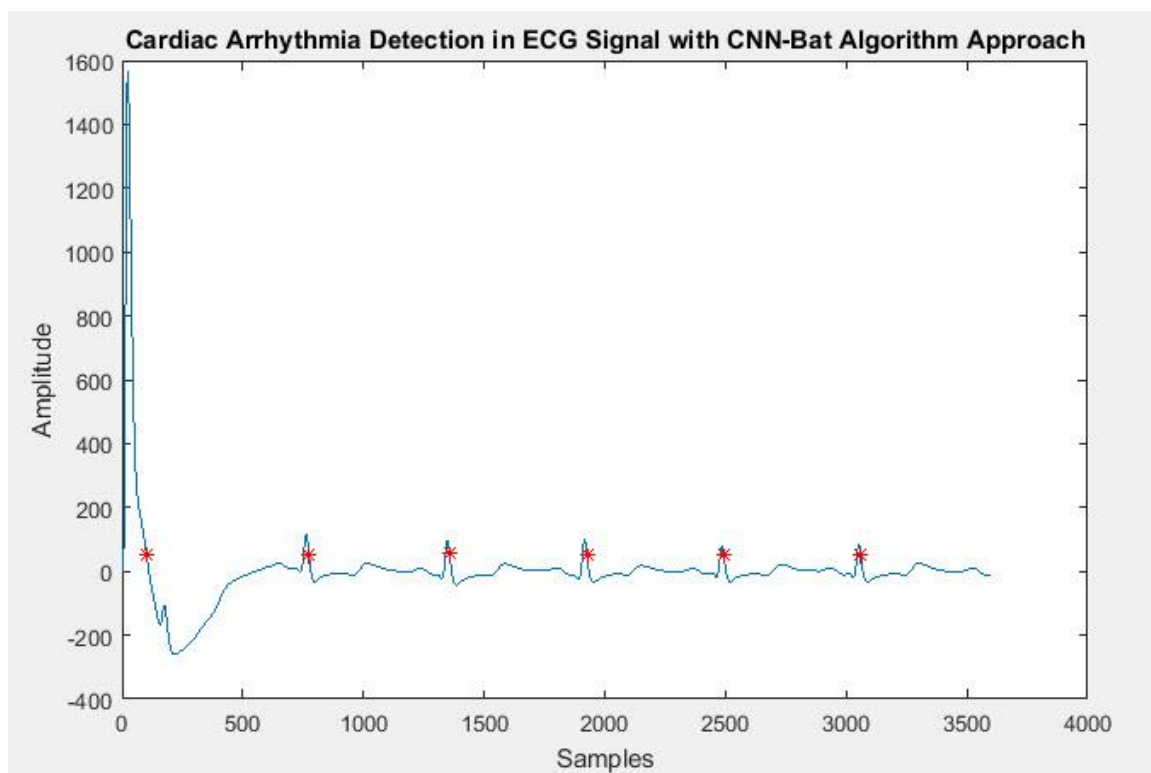
شکل ۱۸. نمایش سیگنال حاصل از طبقه‌بندی و استخراج ویژگی (بخش آبی رنگ) با سیگنال جهش یافته

در شکل ۱۸ دامنه بر حسب زمان (ثانیه) نشان داده می‌شود که مشخص است سیگنال فیلتر شده دارای بهبود بهتری نسبت به سیگنال ورودی خام است. سپس عملیات ترکیب انجام می‌شود که سیگنال‌ها را از هم جداسازی می‌کند و خروجی آن شکل ۱۹ است.



شکل ۱۹. عملیات ترکیب جهت جداسازی سیگنال‌ها

در انتها عملگرهای الگوریتم خفاش نشان می‌دهند که در ۶ ناحیه از سیگنال استخراج شده حاصل از آزمون شبکه عصبی کانولوشن و سپس بهبود برچسب‌های سیگنال به منظور انتخاب ویژگی‌های بهینه با الگوریتم خفاش، آریتمی قلبی وجود دارد که در شکل ۲۰ با رنگ قرمز مشخص شده‌اند.

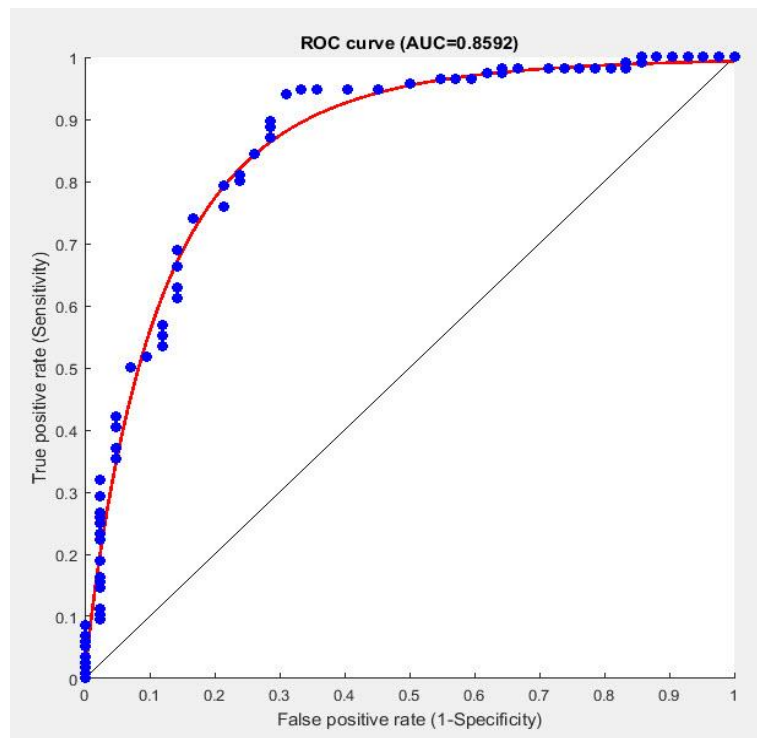


شکل ۲۰. نمایش ۶ ناحیه از آریتمی قلبی

شکل ۲۰ به نمایش دامنه به نرخ نمونه‌برداری شده از سیگنال بعد از عملیات می‌پردازد که اولاً نشان می‌دهد سیگنال در چه شرایطی است و سپس در یک دامنه مشخص، به بررسی آریتمی قلبی می‌پردازد و آن‌ها را با رنگ قرمز مشخص می‌نماید. اینکه سیگنال به چنین دامنه بر حسب نرخ نمونه‌ای رسیده است، بحث و بررسی می‌شود. در این پژوهش از چند معیار ارزیابی استفاده شده است که شامل میانگین مربعات خطا، اوج نسبت سیگنال به نویز<sup>۱</sup>، نسبت سیگنال به نویز<sup>۲</sup>، دقت<sup>۳</sup>، حساسیت<sup>۴</sup>، نرخ ویژگی‌ها<sup>۵</sup> و نمودار است. نتایج ارزیابی به صورت جدول ۳ و نمودار به صورت شکل ۲۱ است.

جدول ۳. نتایج ارزیابی با الگوریتم‌های مختلف

الگوریتم	میانگین مربعات خطا	اوج نسبت سیگنال به نویز (دسی‌بل)	نسبت سیگنال به نویز (دسی‌بل)	دقت (%)	حساسیت (%)	نرخ ویژگی‌ها (%)	AUC
شبکه عصبی کانولوشن مبتنی بر خفاش	۰/۰۹	۱۸/۱۰	۳۰/۰۲	۹۴/۰۲	۸۹/۳۵	۸۱/۲۱	۰/۸۵۹۲



شکل ۲۱. نمودار ROC و مشاهده نتیجه عددی AUC

در ادامه، جدول مقایسه‌ای عملکرد روش‌های تشخیص آریتمی قلبی براساس دقت طبقه‌بندی ارائه شده است. این جدول شامل مطالعات مروری پیشینه و روش پیشنهادی پژوهش حاضر (InceptionNet + الگوریتم خفاش با دقت ۹۴٪) می‌باشد. معیار اصلی مقایسه دقت (Accuracy) است و ستون‌های مرجع، دقت (%، پایگاه داده، روش اصلی برای شفافیت و تحلیل علمی افزوده شده‌اند.

1. Peak signal-to-noise ratio (PSNR)
2. Signal-to-noise-ratio (SNR)
3. accuracy
4. sensitivity
5. specificity

جدول ۴. نتایج ارزیابی روش پیشنهادی با دو روش دیگر

مرجع	دقت (%)	پایگاه داده	روش اصلی	نکات کلیدی
[1]	۹۸/۴۸	نامشخص (20 مجموعه QRS)	شبکه عصبی روبه‌جلو (MLP)	پیش‌پردازش نویز، استخراج QRS، آموزش محدود
[2]	۹۷>	۴۲۰ نمونه (۲۰ رکورد)	تبدیل ویولت & MLP	استخراج ویژگی زمان-فرکانس، دقت بالا در چندکلاسه
[3]	۹۹/۷۱	۲۰۰ نمونه (۱۹۸۰)	PCA & شبکه عصبی احتمالی	کاهش ابعاد، داده قدیمی
[4]	۹۷/۴	۱۸۵ نمونه (۳۰/۷۰ تقسیم)	خوشه‌بندی حداکثر حاشیه & تکاملی	حساسیت ۸۲٫۴٪، ویژگی ۹۸٫۸٪
[5]	۹۷/۶	۳۶۳ نمونه (۳۰ دقیقه)	PCA & انتخاب ویژگی	اعتبارسنجی ۱۰-بخشی، حساسیت ۹۹٪/۲
[6]	۸۷/۷۱	۴۲۰ نمونه (68/16/16)	انتخاب ویژگی همبستگی & شبکه عصبی بازگشتی	میانگین ۱۰۰ شبیه‌سازی
[7]	۹۱/۱۱	۲۷۹ نمونه (90/10)	12 ویژگی ECG	ارزیابی بر اساس AUC
[8]	۹۹/۴۵	۱۲۰۰ ضربان (۳۶۰ نمونه)	K-NN (بهترین)	مقایسه با درخت تصمیم و ANN
[9]	۹۲/۹۷	نامشخص (سیگنال گفتار؟)	CNN با توجه زمانی	استفاده غیراستاندارد از داده گفتار
[10]	۹۹/۵۱	MIT-BIH حذف داده (37% مخرب)	درخت تصمیم	اعتبارسنجی ۱۰-بخشی
[11]	۹۹/۳۱	MIT-BIH ۴۷ بیمار	جنگل تصادفی & تبدیل موجک	AUC بالا، برتری بر درخت تصمیم
[12]	۹۵/۴۲	MIT-BIH (360 Hz)	مدل فازی & حسگر بی‌سیم	انتخاب ویژگی ضروری
[13]	۷۶/۹۲	UCI Arrhythmia (452 نمونه)	ایمنی مصنوعی & وزن‌گیری فازی	تنظیم خودکار، دقت پایین
[14]	۹۳/۱۸	سه پایگاه (360/250 Hz)	شبکه عصبی مصنوعی	حساسیت ۹۵/۳۲٪، ویژگی ۹۱/۰۴٪
[16]	۹۹/۲	MIT-BIH + NSR + BIDMC	ResNet-50 & تبدیل موجک مورز	یادگیری انتقال، F-measure 99.2%
[17]	۹۹/۹۳ تا	MIT-BIH بررسی ۳۰ مقاله	ResNet-50 (بهترین)	F1-score, SMOTEENN تا ۹۹٪/۵۷
[18]	۹۹/۴۱	MIT-BIH + PTB (12- لید)	CNN-BiGRU-Attention	دقت ۹۹/۱۵٪، F1 ۹۹/۲۱٪
[19]	۹۶>	MIT-BIH, INCARTDB (۷۸ مطالعه)	مدل‌های هیبریدی	بررسی سیستماتیک، دقت >۹۶٪
[20]	بالا (دقیق گزارش نشده)	MIT-BIH	Levenberg-Marquardt ANN	مناسب برای دستگاه‌های پوشیدنی
پژوهش حاضر	۹۴/۰۰	استاندارد (تقویت‌شده)	InceptionNet & الگوریتم خفاش	شبیه‌سازی MATLAB، تمرکز بر بهینه‌سازی

### نتیجه‌گیری

این تحقیق، الگوریتم شبکه عصبی عمیق کانولوشن مبتنی بر الگوریتم خفاش را برای تشخیص آریتمی قلبی مورد نظر قرار می‌دهد که برای ارزیابی و بررسی تضمین رویکرد پیشنهادی و مقایسه با یکدیگر در شرایط یکسان (استفاده از مجموعه داده‌های مشابه و نرخ پارامتریک یکسان با عملگرهای متفاوت)، معیارهای مختلفی استفاده شده است که مهم‌ترین آن، دقت، حساسیت و نرخ ویژگی‌ها است که به ترتیب برای روش ارائه‌شده شامل نرخ دقت ۹۴/۰۲٪ است. همین‌طور برای بخش حساسیت نیز برابر ۸۹/۳۵٪ است. نرخ ویژگی‌ها نیز ۸۱/۲۱٪ است. همین‌طور دو مقاله اصلی [۱۴] با ارائه یک روش مبتنی بر شبکه عصبی مصنوعی و [۱۵] به کارگیری شبکه عصبی عمیق تماماً کانولوشن را برای

تشخیص آریتمی قلبی با داده‌های همین تحقیق مورد نظر قرار داده‌اند که نتایج آن‌ها برای دقت به ترتیب برابر  $93/18\%$  و  $92/97\%$  است. مشاهده می‌شود که رویکرد پیشنهادی اصلی این تحقیق به نام شبکه عصبی عمیق کانولوشن مبتنی بر الگوریتم خفاش با دقت  $94/02\%$  نسبت به دو مرجع [۱۴] و [۱۵] با بهبود تقریبی  $0/84\%$  و  $1/05\%$  همراه بوده است. از جمله مهم‌ترین موانعی که پیش روی این تحقیق است، نبود داده‌های بیشتر و یا داده‌های کلینیکی در سطح کشور می‌باشد، لذا کار در سطح تحقیقاتی ارائه می‌گردد. همین‌طور نیاز به سیستم‌های قدرتمند برای پردازش داده‌ها در ابعادی بزرگ تحت‌عنوان کلان داده، مورد نیاز می‌باشد.

در این پژوهش، روشی نوین برای تشخیص آریتمی قلبی بر پایه شبکه عصبی عمیق InceptionNet و الگوریتم بهینه‌سازی خفاش پیشنهاد شد که در محیط MATLAB و با استفاده از مجموعه داده استاندارد تقویت شده، به دقت  $94\%$  دست یافت. این عملکرد، با توجه به معماری چندمقیاسی InceptionNet و قابلیت جست‌وجوی جهانی الگوریتم خفاش، نشان‌دهنده پتانسیل بالای روش پیشنهادی در استخراج ویژگی‌های پیچیده سیگنال‌های ECG و بهینه‌سازی کارآمد پارامترها است. دقت به دست آمده بالاتر از آستانه بالینی اولیه ( $90\%$ ) بوده و روش را به‌عنوان یک سیستم غربالگری هوشمند، قابل پیاده‌سازی در دستگاه‌های پوشیدنی و قابل توسعه به داده‌های چندمنبعی معرفی می‌کند. باین حال، مقایسه با مطالعات برتر ([۱۶]–[۲۰]) که دقت‌های  $99/2\%$  تا  $99/93\%$  را با استفاده از مدل‌های پیشرفته (ResNet-50، CNN-BiGRU-Attention) و پایگاه‌های داده استاندارد (PTB، MIT-BIH) گزارش کرده‌اند، نشان می‌دهد که روش ما در مقایسه با استانداردهای کنونی،  $5-6\%$  فاصله دارد. این فاصله عمدتاً ناشی از پیش‌پردازش محدود، عدم استفاده از تکنیک‌های تقویت داده (مانند SMOTEENN)، و گزارش ناکافی معیارهای ارزیابی (حساسیت، ویژگی، AUC، F1-score) است.

با وجود این، قابلیت بهبود روش پیشنهادی کاملاً مشهود و با اعمال اصلاحاتی نظیر: ادغام پیش‌پردازش پیشرفته (تبدیل موجک مورز، فیلتر کالمن)، استفاده از یادگیری انتقالی و مکانیسم توجه، ترکیب الگوریتم خفاش با بهینه‌سازهای تطبیقی (مانند ADAM)، ارزیابی با اعتبارسنجی  $10$ -بخشی بر روی MIT-BIH، و گزارش ماتریس درهم‌ریختگی و منحنی ROC قابل انجام است.

پیش‌بینی می‌شود دقت به بالای  $98/5\%$  ارتقا یابد و سیستم در سطح تشخیص بالینی رقابتی قرار گیرد. در نهایت، روش پیشنهادی با دقت  $94\%$ ، نقطه شروعی محکم و قابل اعتماد برای توسعه سیستم‌های هوشمند تشخیص آریتمی ارائه می‌دهد و با بهبودهای هدفمند، می‌تواند نقش مؤثری در کاهش مرگ‌ومیر ناشی از آریتمی از طریق تشخیص زودهنگام و دقیق ایفا کند.

## منابع

1. Gothwal H, Kedawat S, Kumar R. Cardiac arrhythmias detection in an ECG beat signal using Fast Fourier Transform and artificial neural network. J Biomed Sci Eng. 2011;4:289-96.
2. Wang JS, Chiang WC, Hsu YL, Yang YT. ECG arrhythmia classification using a probabilistic neural network with a feature reduction method. Neurocomputing. 2013;116:38-45.
3. Zhu B, Ding Y, Hao K. Multiclass maximum margin clustering via immune evolutionary algorithm for automatic diagnosis of electrocardiogram arrhythmias. Appl Math Comput. 2014;227:428-36.
4. Khalaf AF, Owis MI, Yassine IA. Novel technique for cardiac arrhythmia classification using spectral correlation and support vector machines. Expert Syst Appl. 2015;47-56.
5. Mitra M, Samanta RK. Cardiac arrhythmia classification using neural networks with selected features. Procedia Technol. 2013;10:76-84.
6. Jadhav S, Nalbalwar S, Ghatol A. Feature elimination based random subspace ensembles learning for ECG arrhythmia diagnosis. Soft Comput. 2014;18:579-87.

7. Martis RJ, Acharya UR, Adeli H, Prasad H, Tan JH, Chua KC, et al. Computer aided diagnosis of atrial arrhythmia using dimensionality reduction methods on transform domain representation. *Biomed Signal Process Control.*,2016,13:295-305.
8. Yao Q, Wang R, Fan X, Liu J, Li Y. Multi-class arrhythmia detection from 12-lead varied-length ECG using attention-based time-incremental convolutional neural network. *2020;53:174-82.*
9. Kelwade JP, Salankar SS. Prediction of cardiac arrhythmia using artificial neural network. *Int J Comput Appl.* 2015;115(20).
10. Mert A, Kılıc N, Akan A. Evaluation of bagging ensemble method with time-domain feature extraction for diagnosing of arrhythmia beats. *Neural Comput Applic.* 2014;24:317-26.
11. Alickovic E, Subasi A. Medical decision support system for diagnosis of heart arrhythmia using DWT and random forests classifier. *J Med Syst.* 2016;40:108.
12. Huang YP, Huang CY, Liub SI. Hybrid intelligent methods for arrhythmia detection and geriatric depression diagnosis. *Appl Soft Comput.* 2014;14:38-46.
13. Polat K, Sahan S, Gunes S. A new method to medical diagnosis: Artificial immune recognition system (AIRS) with fuzzy weighted pre-processing and application to ECG arrhythmia. *Expert Syst Appl.* 2006;31:264-69.
14. Acharya UR, Fujita H, Oh SL, Raghavendra U, Tan JH, Adam M, et al. Automated identification of shockable and non-shockable life-threatening ventricular arrhythmias using convolutional neural network. *Future Gener Comput Syst.* 2018;79:952-59.
۱۵. زارعی ع، ذاکری ف. طبقه‌بندی تومورهای گلیوما مغز بر پایه شبکه عصبی عمیق ConvNet و منحنی براونی. فصلنامه پیشرفت‌های مهندسی در حوزه پزشکی و مواد. ۱۴۰۴؛۱(۳):۶۵-۸۴.
16. Daydulo YD, Thamineni BL, Dawud AA. Cardiac arrhythmia detection using deep learning approach and time frequency representation of ECG signals. *BMC Med Inform Decis Mak.* 2023;23:232.
17. Reshad AI, Nino V, Valero M. Deep Learning-Based Detection of Arrhythmia Using ECG Signals – A Comprehensive Review. *Vasc Health Risk Manag.* 2025;21:685-703.
18. Bai X, Dong X, Li Y, Liu R, Zhang H. A hybrid deep learning network for automatic diagnosis of cardiac arrhythmia based on 12-lead ECG. *Sci Rep.* 2024;14:24441.
19. Ansari Y, Mohammed OM, Qaraqe K, Serpedin E. Deep learning for ECG Arrhythmia detection and classification: an overview of progress for period 2017–2023. *Front Physiol.* 2023;14:1246746.
20. Sangeetha RG, Anand KK, Sreevatsan B, Kumar VA. Cardiac arrhythmia detection using artificial neural network. *Heliyon.* 2024;10(12) e33089.

استناد به این مقاله: زارعی، علیرضا، و جاویدنژاد، الهه. (۱۴۰۵). تشخیص آریتمی قلبی از سیگنال‌های ECG با رویکرد شبکه عصبی عمیق InceptionNet و الگوریتم بهینه‌سازی خفاش. فصلنامه پیشرفت‌های مهندسی در حوزه‌ی پزشکی و مواد، ۱(۴)، ۵۴-۷۷.

