

**Detection of cardiac arrhythmias based on optimized deep features**

**Negar Jannati<sup>1</sup>, M.Sc, Mehdi Taghizadeh<sup>2</sup>, Assistant Professor, Omid Mahdiyar<sup>3</sup>, Assistant Professor, Babak Gholami<sup>4</sup>, Assistant Professor**

<sup>1</sup>Faculty of Engineering, Kazerun Branch, Islamic Azad University, Kazerun, Iran  
negar12jannati@gmail.com

<sup>2</sup>Faculty of Engineering, Kazerun Branch, Islamic Azad University, Kazerun, Iran  
Mehdi.taghizadeh@iau.ac.ir

<sup>3</sup>Faculty of Engineering, Kazerun Branch, Islamic Azad University, Kazerun, Iran  
mahdiyar\_omid@yahoo.com

<sup>4</sup>Faculty of Engineering, Kazerun Branch, Islamic Azad University, Kazerun, Iran  
Gholamibox@gmail.com

**Received:** 06 November 2023

**Revised:** 24 November 2024

**Accepted:** 24 November 2024

**Abstract**

According to the World Health Organization report, cardiovascular diseases are now recognized as the leading cause of human mortality. Cardiovascular diseases, specifically vascular diseases, are the primary cause of death worldwide, accounting for 46% of mortality, according to the latest reports. On average, 200 individuals lose their lives daily due to heart disease, while 25% of cases are reversible and can be resuscitated. Rapid, timely, and accurate diagnosis, along with specialized medical care for patients with these diseases, can significantly prevent sudden death and further complications. Electrocardiogram (ECG) recording is an easy, cost-effective, and highly effective method; therefore, the use of electrocardiography and familiarity with its principles, operation, and interpretation aids in diagnosing heart diseases. The electrocardiographic signal is the most important and fundamental signal related to the heart, with minimal complexity in recording and processing, and is used to diagnose many cardiac conditions. In this article, deep learning is used to differentiate and classify cardiac arrhythmias. Using feature selection and the TFCRF weighting method, 10 deep features are extracted and input into the classifier. A neural network classifier with an accuracy of 86.99% is selected as the top classifier, effectively distinguishing arrhythmias from each other.

**Keywords:** ECG signal, cardiac arrhythmias, SVM, neural network

**Corresponding Author:** Dr. Mehdi Taghizadeh

**Corresponding Author Address:** Department of Electrical and Computer - Mellat Blvd. -Islamic Azad University- Kazerun Branch, Iran

## تشخیص آریتمی‌های قلبی مبتنی بر ویژگی‌های عمیق بهینه شده

نگار جنتی<sup>۱</sup>، دانشجوی ارشد، مهدی تقی زاده<sup>۲\*</sup>، استادیار، امید مهدی یار<sup>۳</sup>، استادیار، بابک غلامی<sup>۴</sup>، مربی

۱- دانشکده فنی مهندسی، واحد کازرون، دانشگاه آزاد اسلامی، کازرون، ایران

negar12jannati@gmail.com

۲- دانشکده فنی مهندسی، واحد کازرون، دانشگاه آزاد اسلامی، کازرون، ایران

mehdi.taghizadeh@iau.ac.ir

۳- دانشکده فنی مهندسی، واحد کازرون، دانشگاه آزاد اسلامی، کازرون، ایران

mahdiyar\_omid@yahoo.com

۴- دانشکده فنی مهندسی، واحد کازرون، دانشگاه آزاد اسلامی، کازرون، ایران

ba.gholami@iau.ac.ir

تاریخ پذیرش مقاله: ۱۴۰۳/۰۹/۰۴

تاریخ بازنگری مقاله: ۱۴۰۳/۰۹/۰۴

تاریخ ارسال مقاله: ۱۴۰۲/۰۸/۱۵

**چکیده:** براساس گزارش سازمان بهداشت جهانی بیماری‌های قلبی امروزه مهمترین عامل تهدید کننده زندگی انسان به حساب می‌آیند. بیماری‌های قلبی عروقی نخستین علت مرگ و میر بیماری در دنیا هستند و طبق آخرین گزارشات ۴۶٪ موارد مرگ و میر را به خود اختصاص داده اند. به طور متوسط روزانه ۲۰۰ نفر در اثر بیماری قلبی جان خود را از دست می‌دهند در حالی که ۲۵٪ موارد، قابل احیا و برگشت پذیر می‌باشند. تشخیص سریع، به موقع و دقیق و مراقبت ویژه پزشکی از بیماران مبتلا به این امراض می‌تواند تا حد زیادی از مرگ ناگهانی و مشکلات بیشتر آنها جلوگیری نماید. با توجه به اینکه ثبت نوار قلب (الکتروکاردیوگرام) روشی آسان، کم هزینه و در عین حال بسیار ثمربخش است، استفاده از الکتروکاردیوگرام و آشنایی با اصول کار، شناخت و تفسیر آن ما را در تشخیص بسیار کمک می‌کند. سیگنال الکتروکاردیوگرافی مهمترین و اصلی ترین سیگنال وابسته به قلب بوده و دارای پیچیدگی کم در ثبت و پردازش می‌باشد و برای تشخیص بسیاری از عارضه های قلبی مورد استفاده قرار می‌گیرد. در این مقاله برای تفکیک و طبقه بندی آریتمی‌های قلبی از یادگیری عمیق استفاده شده که با استفاده از انتخاب ویژگی و روش وزن دهی TFCRF، ۱۰ ویژگی عمیق استخراج شده و به عنوان ورودی وارد طبقه بندی کننده می‌شود و طبقه بندی کننده شبکه عصبی با درصد ۹۹/۸۶ به عنوان طبقه بندی کننده برتر انتخاب شده است و آریتمی‌ها را با دقت خوبی از هم تفکیک می‌کند.

**کلمات کلیدی:** سیگنال ECG، آریتمی های قلبی، SVM، شبکه عصبی عمیق

نام نویسنده‌ی مسئول: دکتر مهدی تقی زاده

نشانی نویسنده‌ی مسئول: کازرون- بلوار ملت- دانشگاه آزاد اسلامی واحد کازرون- دانشکده مهندسی برق و کامپیوتر

## ۱- مقدمه

الکتروکاردیوگرام بیشترین کاربرد را در تشخیص آریتمی های قلبی دارد. آریتمی ها بسیار متنوع بوده و به انواع مختلف تقسیم می شوند. در یک تقسیم بندی کلی آریتمی ها یا موجب تعداد ضربان کم قلب می شوند که به آن ها برادیکاردی گفته می شود، یا موجب تعداد ضربان بیشتر از نرمال قلب می شوند که به آن ها تاکیکاردی اطلاق می شود. مطالعات نشان می دهد که حدود ۸۰٪ از مرگ های ناگهانی نتیجه آریتمی های بطنی است. بنابراین، تشخیص زودرس و دقیق آریتمی ها بسیار مهم و در روند بهبود بسیار موثر است. جهت انجام این پژوهش از داده های پایگاه داده ی فیزیوت استفاده شد [۱]. در این دیتابیس، ECG به طور نرمال با قرار دادن الکترودهای سطحی بر روی قفسه سینه، دست و پاها ثبت گردیده است. این دیتابیس شامل انواع آریتمی های قلبی می باشد. این باعث می شود که عملکرد شرایط نامنظم قلبی را نیز ارزیابی کند. در این مقاله، ویژگی های عمیق بر مبنای شبکه عصبی کانولوشن با معماری الکس نت استخراج می گردند. سپس برای کاهش تعداد ویژگی ها، ویژگی های برتر مورد گزینش قرار گرفته و انتخاب می شوند تا بتواند به عنوان ورودی به طبقه بندی کننده وارد می شوند. ویژگی های برتر به طبقه بندی کننده های مختلف مانند شبکه عصبی و ماشین بردار پشتیبان<sup>۱</sup> (SVM) و K نزدیک ترین همسایه<sup>۲</sup> (KNN) جهت تشخیص آریتمی های قلبی داده می شود. برای ارزیابی عملکرد طبقه بندی از پارامترهای حساسیت، قدرت تشخیص و صحت استفاده خواهد شد [۲].

## ۲- بیان مسأله

اختلال قلبی یک هشدار جدی برای سلامت عمومی است و در بیشتر موارد، باعث آسیب شدید یا مرگ می شوند. بر اساس گزارش های سازمان بهداشت جهانی تقریباً ۳۶ میلیون نفر در سال به دلیل بیماری های قلبی عروقی جان خود را از دست می دهند. تشخیص آریتمی های قلبی به صورت مستمر با استفاده از مهمترین و وابسته ترین سیگنال به قلب یعنی الکتروکاردیوگرام انجام می گیرد [۳].

متخصصان قلب با تفسیر ECG به صورت بصری و دستی مشکلات را تشخیص می دهند که امری خسته کننده و طاقت فرسا و هزینه بر می باشد. با ظهور تکنولوژی، چندین ابزار تشخیص خودکار برای طبقه بندی و تشخیص آریتمی ها برای کمک به پزشکان توسعه یافته است [۴]. استفاده از روش های خودکار بر مبنای ویژگی های عمیق روند تشخیص را بهبود می دهد. اما تعداد زیاد ویژگی های عمیق سرعت تشخیص را کاهش و زمان بر می کند. از این رو استفاده از ویژگی های برتر در تشخیص، زمان تشخیص را به شدت کاهش می دهد. به طور کلی هدف این پژوهش تشخیص آریتمی های قلبی پرخطر و متداول مبتنی بر ویژگی های عمیق بهینه شده است. بنابراین می توان با بررسی و انجام آن با دقت و سرعت بالایی در امر تشخیص به پزشک کمک نمود.

## ۳- کارهای مرتبط گذشته

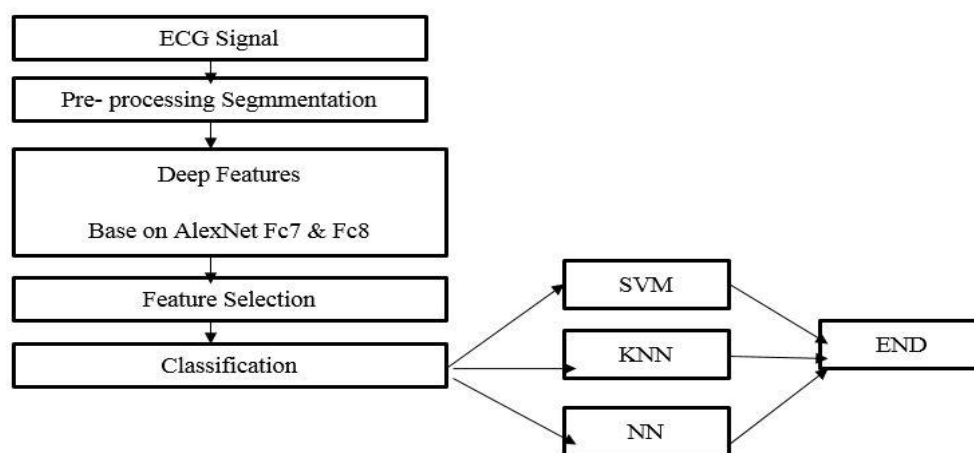
یادگیری عمیق نقش بسزائی در خودکار نمودن طبقه بندی آریتمی ها دارد. شبکه عصبی کانولوشنال، CNN، یک ابزار پیشرفته برای طبقه بندی کامپیوتری در نظر گرفته می شود [۵].

تایانگ و همکاران روشی را برای سیگنال های ECG را با استفاده از آنتروپی بسته موجک (WPE) و الگوریتم های تصادفی (RF) به دنبال توصیه های انجمن پیشرفت ابزار دقیق پزشکی (AAMI) و طرح بین المللی طبقه بندی کردند [۶]. در [۷] طبقه بندی الگوریتم های بهینه (OPF) را برای تشخیص خودکار آریتمی های قلبی در الگوهای ECG معرفی کرد. در روشی دیگر برای طبقه بندی از ماشین بردار پشتیبان (SVM) استفاده کرده است. روشی را برای طبقه بندی بیماری های قلبی براساس تجزیه و تحلیل ECG با استفاده از ۲ روش Fuzzy (FCM) و SVM پیشنهاد کرد [۸]. ژانگ یک الگوریتم طبقه بندی الکتروکاردیوگرام مخصوص بیماران خاص مبتنی بر شبکه های عصبی (RNN) با استفاده از همبستگی نمونه های سیگنال ECG و ضربان قلب متفاوت با تعداد ضربان قلب ارائه داد [۹]. در [۱۰] یک روش طبقه بندی مخصوص نوار قلب برای بیمار در زمان واقعی را بر اساس شبکه عصبی کانولوشن پیشنهاد کرد، که می تواند صرفاً برای طبقه بندی ثبت ECG طولانی بیماران استفاده شود.

لی یک روش مبتنی بر شبکه عصبی کانولوشن برای تحقق طبقه‌بندی ۵ نوع سیگنال آریتمی معمولی پیشنهاد کرد [۱۱]. در این تحقیق آریتمی‌ها را با استفاده از شبکه عصبی کانولوشن با ۴۰۹۶ ویژگی عمیق بدست آمده بدون دخالت دست از هم تفکیک نمود. در این تحقیق از شبکه عصبی برای تفکیک ۵ نوع آریتمی از هم استفاده شده است. بین یک سیستم کنترل ECG یکپارچه با رادار مبتنی بر فرکانس‌های رادیویی (IR-UWB) بر اساس شبکه عصبی کانولوشن پیشنهاد کرد [۱۲]. ژوئن پیشنهاد یک روش طبقه‌بندی آریتمی ECG موثر با استفاده از شبکه عصبی کانولوشن دو بعدی است که به طور کلی عملکرد برجسته‌ای را در زمینه تشخیص الگو نشان می‌دهد [۱۳].

#### ۴- روش کار

شناسایی زود هنگام بیماری‌های قلبی منجر به کاهش اثرات مخرب برای فرد بیمار می‌شود. مطالعه و تحقیقات زیادی برای شناسایی و تشخیص بیماری‌های قلبی صورت گرفته است، که در این تحقیق به مطالعه و ارائه روشی برای شناسایی آریتمی‌های قلبی پرداخته شده است که برای این منظور از یک شبکه عصبی کانولوشن و یادگیری عمیق استفاده شده است. لذا در این تحقیق با استفاده از شبکه عصبی کانولوشن بر مبنای معماری AlexNet با ساختار لایه‌های تماماً متصل fc7 و fc8 و ویژگی عمیق بدون دخالت دست استخراج شده و در نهایت آریتمی‌های قلبی را با طبقه‌بندی کننده‌های KNN، NN و SVM از هم تفکیک نمودیم. شکل (۱) فلورچارت الگوریتم کلی برنامه را نشان داده است.



شکل (۱): فلورچارت کلی برنامه

#### ۴-۱- پایگاه داده


در این تحقیق از سیگنال‌های الکتروکاردیوگرافی برچسب خورده پایگاه داده Arrhythmia-BIH-MIT استفاده شده است. با توجه به نیاز مقاله از سیگنال‌های ECG پنج فرد بیمار به شماره‌های ۱۰۰ و ۱۰۵ و ۱۰۹ و ۱۱۸ و ۱۲۴ استفاده شد، در جدول ۱ مشخصات ۵ سیگنال کلی نمایش داده شده است. سیگنال‌های دانلود شده شامل موارد زیر است:

- ۱- ضربان طبیعی (NOR)
- ۲- ضربان بسته شدن شاخه چپ (LBBB)
- ۳- ضربان بسته شدن شاخه راست (RBBB)
- ۴- ضربان انقباض بطن زودرس (PVC)
- ۵- ضربان انقباض زودرس دهلیزی (APC).


جدول ۱- مشخصات سیگنال های استفاده شده در مقاله

شماره سیگنال	طول سیگنال	سن	جنسیت	آریتمی ها
۱۰۰	۶۵۰۰۰۰	۶۹	مرد	Nor APC
۱۰۵	۶۵۰۰۰۰	۷۳	زن	Nor PVC
۱۰۹	۶۵۰۰۰۰	۶۴	مرد	LBBB PVC
۱۱۸	۶۵۰۰۰۰	۶۹	مرد	RBBB APC PVC
۱۲۴	۶۵۰۰۰۰	۷۷	مرد	RBBB APC PVC

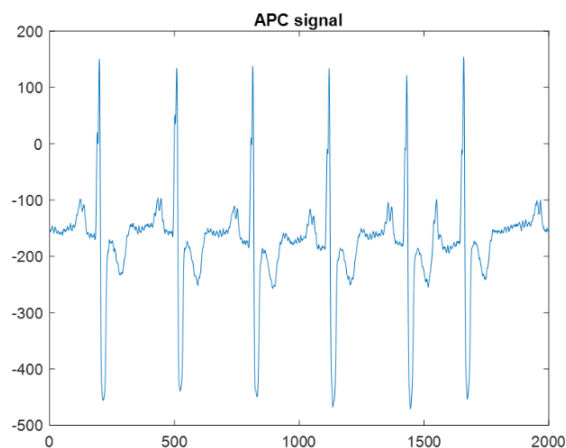
شکل های (۲) تا (۶) چند نمونه سیگنال های دانلود شده و استفاده شده در مقاله با مشخصات گفته شده در جدول ۱ می باشد.



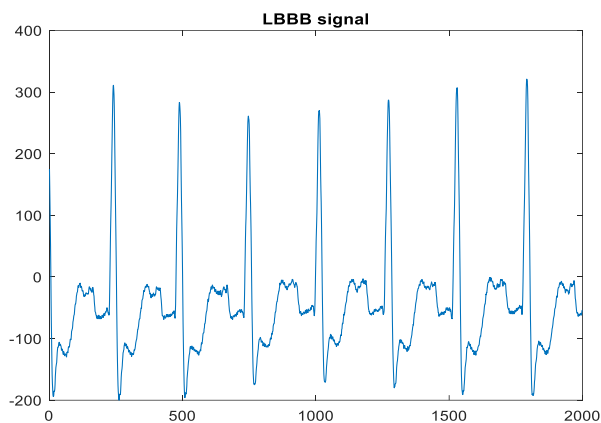
شکل (۲): نمونه سیگنال فرد سالم



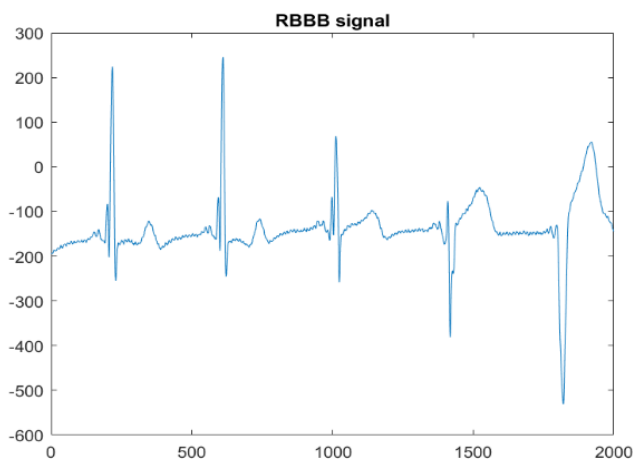
شکل (۳): نمونه سیگنال قلبی دارای آریتمی PVC



شکل (۴): نمونه سیگنال قلبی دارای آریتمی APC



شکل (۵): نمونه سیگنال قلبی دارای آریتمی LBBB



شکل (۶): نمونه سیگنال قلبی دارای آریتمی RBBB

#### ۴-۲- پیش پردازش

این مرحله پیش پردازش نامیده می شود که هدف آن کاهش نویز سیگنال و کم شدن حجم داده است که سیگنال مورد نظر برای مرحله استخراج ویژگی آماده شود. که شامل موارد زیر است:

## ۴-۲-۱- حذف نویز

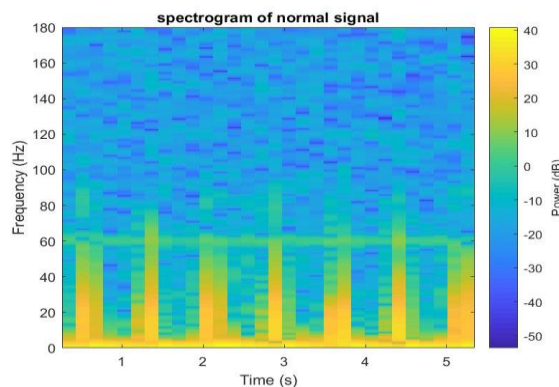
برای تضعیف باندهای فرکانسی شناخته شده مانند نویز ناشی از شبکه برق (۵۰ هرتز یا ۶۰ هرتز) از فیلتر ناچ استفاده می‌شود. برای فیلترهای احتمالی بر روی سیگنال از فیلتر میانگذر ۰-۱۰۰ هرتز تا ۱۵۰ هرتز استفاده می‌شود که نویزهای احتمالی را تضعیف کند. اما سیگنال‌های موجود در سایت دارای نویزهای بسیار کم می‌باشند و در این تحقیق بدلیل اینکه هدف تغییر ندادن ماهیت اصلی سیگنال می‌باشد، هیچ فیلتری بر روی سیگنال اعمال نمی‌شود.

## ۴-۲-۲- قطعه بندی

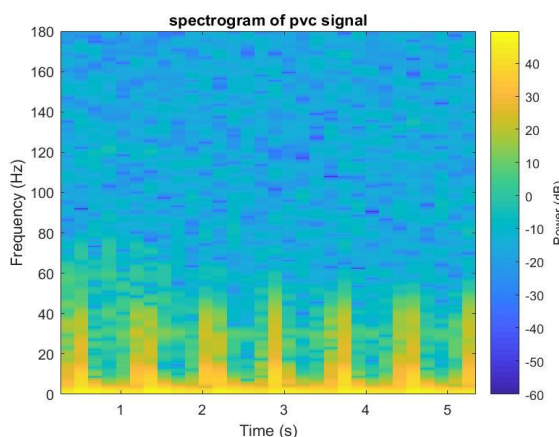
برای هر سیگنال الکتروکاردیوگرافی موجود در پایگاه داده، آریتمی‌های مختلف و نیز تفسیری که توسط متخصصان قلب بر روی آن صورت گرفته است، نیز موجود است. با توجه به اینکه ممکن است یک سیگنال در زمانهای مختلف نشاندهنده وجود بیماریهای متفاوت باشد، لازم است قطعاتی از سیگنال که حاوی یک بیماری خاص هستند جدا شوند. این امر باعث افزایش دقت تشخیص سیستم خواهد شد. اطلاعات موجود در پایگاه داده حاکی از این است که نرخ ضربانهای قلبی در برخی از سیگنال‌های ثبت شده در سه سیکل از ضربان قلب رخ دهد.

بنابراین، برای هر بیماری، سه دوره متوالی از سیگنال الکتروکاردیوگرافی در محل وقوع بیماری به عنوان داده مورد نظر برای این بیماری انتخاب شده است. به دلیل اینکه فرکانس نمونه برداری ۳۵۰ می‌باشد لذا ۱۰۰۰ نمونه برای هر پنجره در نظر گرفته شده که حداقل ۳ سیکل را در بر بگیرد.

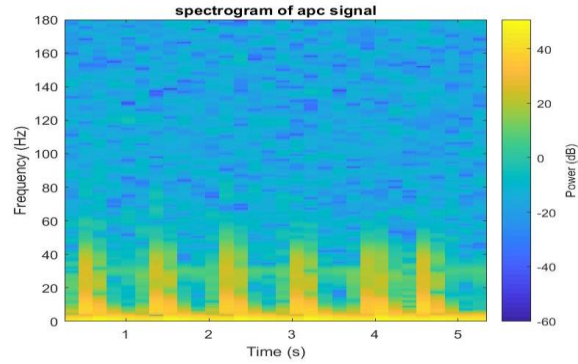
سیگنال‌های دارای آریتمی مرتب شده و به صورت قطعه قطعه (پنجره‌های ۲۰۰۰ نمونه ای که برای نمایش بهتر از ۲۰۰۰ نمونه استفاده کرده ایم ولی در حالت کلی هر ۱۰۰۰ نمونه نشان دهنده یک بیماری خاص است) جدا شده و نمایش داده شده اند تا بتوان عملیات پردازش های بعدی از جمله استخراج تصویر زمان فرکانس سیگنال و استخراج ویژگی را بتوان به صورت مجزا انجام داد و در نهایت نتایج را گزارش داد.




شکل (۷): تصویر زمان فرکانس سیگنال نرمال ECG



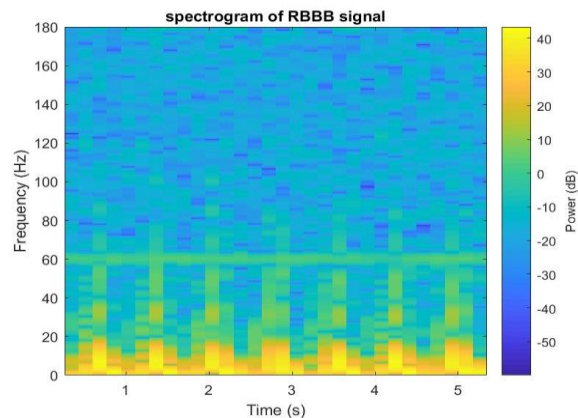
شکل (۸): تصویر زمان فرکانس سیگنال ECG دارای آریتمی PVC



شکل (۹): تصویر زمان فرکانس سیگنال ECG دارای آریتمی APC



شکل (۱۰): تصویر زمان فرکانس سیگنال ECG دارای آریتمی LBBB



شکل (۱۱): تصویر زمان فرکانس سیگنال ECG دارای آریتمی RBBB

#### ۴-۳- تبدیل سیگنال به تصویر

در این قسمت ابتدا سیگنال خود را به تصویر تبدیل کردیم، سپس در بخش استخراج ویژگی توسط شبکه عصبی کانولوشن و معماری الکس نت ۱۰۰۰ ویژگی عمیق از تصاویر استخراج کردیم. با توجه به آنکه از شبکه عصبی کانولوشن استفاده کرده ایم و شبکه عصبی کانولوشن به طور قطع اعلام می کند که ورودی آن باید تصویر باشد به این منظور برای تبدیل سیگنال به تصویر مراحل زیر را انجام داده ایم:

۱. تبدیل فوریه
۲. تبدیل فوریه سریع
۳. اسپکتوگرام تصویر



در این تحقیق از ویژگی تبدیل فوریه برای رسیدن به تصویر زمان فرکانس سیگنال استفاده شده و نتایج را در نمونه شکل های ۷ الی ۱۱، تصویر زمان-فرکانس سیگنال های نرمال و دارای آریتمی با استفاده از اسپکتوگرام، ترسیم کرده ایم.

#### ۴-۴- استخراج ویژگی

استخراج ویژگی انجام عملیاتی بر روی داده ها و سیگنال هاست که در آن، ویژگی های بارز و تعیین کننده و مهم در تشخیص و بررسی داده ها، مشخص می شوند تا بتوان از آنها در تشخیص و تفکیک و شناسایی گروه ها استفاده کرد. هدف استخراج ویژگی این است که داده های خام به شکل قابل استفاده تری برای پردازش های آماری بعدی درآیند. در این مرحله تصاویر به صورت تصادفی به عنوان ورودی وارد شبکه عصبی کانولوشن می شوند و فرآیند آموزش و آزمایش با نسبت ۷۰٪ به ۳۰٪ بر روی داده ها انجام می شود.

#### ۴-۴-۱- ویژگی های عمیق

استخراج ویژگی از تصاویر یک کار بسیار پرکاربرد و حساس می باشد برای تشخیص و طبقه بندی که هرچه این استخراج ویژگی بهتر انجام گرفته باشد، تشخیص و تفکیک به مراتب بهتر صورت می گیرد. هر چه این کار بدون دخالت دست صورت بگیری خطای انسانی ناشی از خستگی و بی حوصلگی کاهش می یابد، که این کار فرایند تشخیص را مرتفع می سازد. به همین دلیل امروزه به سمت استخراج ویژگی بدون دخالت دست، روی آورده شده است. در اینجا با استفاده از شبکه عصبی کانولوشن ویژگی های عمیق از تصاویر استخراج می گردد.

#### ۴-۴-۲- شبکه عصبی کانولوشن

در دسته بندی تصاویر با استفاده از شبکه عصبی کانولوشن، یک روش قدرتمند است. یک کامپیوتر نیز برای درک و تشخیص تصویرهای پیچیده، ابتدا ویژگی های<sup>۳</sup> ساده تر آن تصویر مانند لبه ها و خم ها را تشخیص می دهد. در یک شبکه عصبی، لایه های متعددی وجود دارند؛ در هر یک از این لایه ها، ویژگی های خاصی تشخیص داده می شوند و در نهایت، در لایه ی آخر، تصویر به طور کامل شناسایی می شود. فرایند کلی نحوه کار یک شبکه عصبی کانولوشن به صورت بالا می باشد. همان طور که اشاره شد، در یک شبکه عصبی کانولوشن یا پیچشی، کامپیوتر یک تصویر را به عنوان ورودی می گیرد؛ سپس این تصویر وارد یک شبکه ی پیچیده با چندین لایه ی پیچشی و غیر خطی می شود. در هر یک از این لایه ها، عملیات هایی انجام می شود و در انتها بر روی خروجی، یک کلاس یا درصد وقوع چند کلاس مختلف نشان داده می شود. شبکه عصبی کانولوشن یا پیچشی<sup>۴</sup> را می توان به عنوان یک شناساگر ویژگی<sup>۵</sup> در نظر گرفت. منظور از ویژگی در این جا، چیزهایی مانند خط صاف، یک رنگ ساده یا یک انحناست.

در یک شبکه عصبی، علاوه بر لایه ی توضیح داده شده، لایه های دیگری نیز وجود دارند. این لایه ها وظایف و عملکردهای گوناگونی دارند. به طور کلی، لایه های داخلی، مسئول نگهداری و حفظ ابعاد و امور غیر خطی هستند. آخرین لایه در شبکه عصبی کانولوشن نیز از اهمیت خاصی برخوردار است.

در لایه آخر یک شبکه عصبی کانولوشن، خروجی سایر لایه ها، به عنوان ورودی دریافت می شود. خروجی لایه آخر هم یک بردار  $N$  بعدی است.

$N$  تعداد کلاس های موجود است. به عنوان مثال اگر شبکه ی شما، یک شبکه برای شناسایی اعداد باشد، تعداد کلاس ها ده تاست؛ چون ده رقم وجود دارد.

در بردار  $N$  بعدی، هر مولفه، احتمال وقوع یک کلاس را نشان می دهد. کاری که لایه آخر یک شبکه عصبی کانولوشن می کند آن است که به ویژگی های لایه های سطح بالا نگاه می کند و میزان مطابقت این ویژگی ها را با هر کلاس مقایسه می کند؛ هر چه این مطابقت بیشتر باشد، احتمال وقوع آن کلاس، بالاتر معرفی می شود.

که در این مقاله از شبکه عصبی کانولوشن یا پیچشی برای استخراج ویژگی های عمیق بدون دخالت دست استفاده شده است.

شبکه عصبی کانولوشن AlexNet از شبکه های پیش آموزش دیده است که توانایی طبقه بندی بیش از ۱۰۰۰ کلاس را دارا می باشد.

در این پژوهش به چند طریق از شبکه عصبی کانولوشن و از لایه تمام متصل fc7 و fc8 استخراج ویژگی شده است.

۱- در روش اول به واسطه لایه تمام متصل fc8 از شبکه عصبی کانولوشن ۱۰۰۰ ویژگی استخراج شده و سپس از طریق انتخاب ویژگی ۱۰ ویژگی برتر انتخاب می شود.

۲- در روش دوم به واسطه لایه تمام متصل fc7 از شبکه عصبی کانولوشن ۲۰۰۰ ویژگی استخراج شده و سپس از طریق انتخاب ویژگی ۲۰ ویژگی برتر انتخاب میگردد.

۳- در روش دوم به واسطه لایه تمام متصل fc7 از شبکه عصبی کانولوشن ۲۰۰۰ ویژگی استخراج شده و سپس از طریق انتخاب ویژگی ۵۰ ویژگی برتر انتخاب میگردد.

در مرحله بعد، پس از انتخاب ویژگی های برتر، ویژگی های برتر به عنوان ورودی وارد طبقه بندی کننده ها می شود و خروجی آنها با هم مقایسه می شود تا بهترین روش انتخاب شود. در این جا برای اینکه زمان محاسبات و بار محاسبات کاهش پیدا کند از روش کاهش ویژگی ها و یا انتخاب ویژگی های بهینه استفاده نمودیم که برای روش انتخاب ویژگی از روش وزن دهی TFCRF استفاده شده است. مراحل گفته شده در بالا را تست می کنیم و نتایج را در ادامه شرح خواهیم داد.

#### ۴-۵- روش وزن دهی ویژگی پیشنهادی TFCRF

اکثر روش های وزن دهی ویژگی فوق در ابتدا برای کاربردهای بازیابی اطلاعات مطرح شده اند و سپس در حوزه طبقه بندی مستندات به کار گرفته شده اند. لذا در این روش ها چگونگی توزیع ویژگی  $t_k$  در طبقه  $C_j = C$  نادیده گرفته شده است. بطورمثال همانطور که اشاره شد در روشهای مبتنی بر IDF وزن ویژگی  $t_k$  رابطه معکوسی با تعداد مستندات که دارای این ویژگی هستند دارد. به بیان دیگر هرچه تعداد مستندات که دارای ویژگی  $t_k$  هستند بیشتر باشد قدرت آن ویژگی در متمایز کردن مستندات از یکدیگر پائین تر بوده و در نتیجه وزن کمتری به آن ویژگی اختصاص داده می شود. اگرچه این فرض در حوزه بازیابی مستندات صحیح می باشد اما در حوزه طبقه بندی مستندات نیازمند اعمال اصلاحاتی است تا وزن ویژگی تابعی از طبقه مستندات که دارای آن ویژگی هستند نیز باشد. واضح است هرچه تعداد مستندات که دارای ویژگی  $t_k$  هستند زیاد باشد ولی اکثر آن مستندات متعلق به طبقه  $C_j$  باشند، ویژگی  $t_k$  نه تنها ویژگی نامناسبی نبوده بلکه باید به عنوان یک ویژگی بسیار مناسب و مهم جهت تمایز طبقه  $C_j$  از سایر طبقات در نظر گرفته شود و وزن بالایی در آن طبقه به خود اختصاص دهد. از طرفی هرچه مستندات که ویژگی  $t_k$  آنها وجود دارد متعلق به طبقاتی غیر از طبقه  $C_j$  باشند باید وزن آن ویژگی در طبقه  $C_j$  پائین باشد.

در معیار rf تعریف شده در [۱۷] راه حل اولیه ای برای مساله فوق ارائه شده است. زیرا در آن وزن ویژگی  $t_k$  در مستند  $d_i$  رابطه مستقیمی با تعداد مستندات دارد که از طبقه  $C_d$  بوده و رابطه معکوسی با تعداد مستندات دارد که از طبقه ای غیر از  $C_d$  هستند. اما فاکتور If در روش فوق مستقل از تعداد مستندات موجود در هر طبقه محاسبه می شود. در صورتی که توجه به همین عامل می تواند کارایی طبقه بندی کننده مستندات را تا حد قابل توجهی افزایش دهد.

لذا در روش پیشنهادی ما برای وزن دهی دقیق تر به ویژگی ها به جای rf دو فاکتور positiveRF (فاکتور ارتباط مثبت) و negativeRF (فاکتور ارتباط منفی) تعریف می شود positiveRF نسبت تعداد مستندات از طبقه  $C_j$  را که ویژگی  $t_k$  را دارند به کل مستندات آن طبقه نشان می دهد و negativeRF نسبت مجموع تعداد مستندات از طبقه غیر  $C_j$  را که ویژگی  $t_k$  را دارند به کل مجموع مستندات طبقه ات غیر  $C_j$  را نشان می دهد که به صورت زیر تعریف می شود:

(۱)

$$positiveRF(t_k \cdot C_j) = |D(t_k \cdot C_j)| / |D(C_j)|$$

(۲)

$$\text{negative}(t_i, C_i) = \frac{\sum_{m=1, m \neq j}^{|C|} |D(t_k, c_m)|}{\sum_{m=1, m \neq j}^{|C|} |D(C_m)|}$$

که در رابطه فوق  $|D(C_j)|$  تعداد مستندات طبقه  $C_j$  و  $|D(t_k, c_m)|$  تعداد مستندات از مجموعه  $D$  و طبقه  $C_j$  که دارای ویژگی  $t_k$  می باشد است.

از رابطه (۱) و (۲) مقدار ارزش فاکتور ارتباط هر طبقه (crfValue) به طور کلی به صورت زیر تعریف می شود

$$\text{crfValue}(t_k, c_j) = \frac{\text{positive}(t_k, c_j)}{\text{negative}(t_k, c_j)}$$

مشخص است ارزش فاکتور ارتباط هر طبقه رابطه مستقیم با فاکتور ارتباط مثبت و رابطه معکوس با فاکتور ارتباط منفی دارد رابطه پیشنهادی برای وزن دهی ویژگی  $t_k$  در مستند  $d_i$  به صورت رابطه (۴) است:

$$w_{ki} = \log(\text{tf}(t_k, d_i) * \text{crfValue}(t_k, c_{d_i}))$$


که در آن  $c_{d_i} \in C$  طبقه مستند  $d_i$  است.

برای از بین بردن اثر طول مستند بر دقت و کارایی طبقه بندی کننده، از نرمال کردن استفاده شده تا وزن ویژگی ها در دامنه (۰.۱) محدود شود. در نتیجه رابطه نهایی پیشنهادی بصورت رابطه (۵) خواهد آمد:

$$w_{ki} = \frac{\log(\text{tf}(t_k, d_i) * \text{crfValue}(t_k, c_{d_i}))}{\sqrt{(\log(\text{tf}(t_k, d_j) * \text{crfValue}(t_k, c_{d_i}))^2)}$$


نشان داده خواهد شد که این روش وزن دهی ویژگی برای طبقه بندی مستندات نسبت به سایر روش های شرح داده شده در بخش ۲ از کارایی بالاتری برخوردار است. نتایج را در ادامه شرح خواهیم داد.

۱- در روش اول به واسطه لایه تمام متصل fc8 از شبکه عصبی کانولوشن ۱۰۰۰ ویژگی استخراج شده و سپس از طریق انتخاب ویژگی ۲۰ ویژگی برتر انتخاب می شود. سپس می توان هر ویژگی را که بهتر می تواند تفکیک کنند را انتخاب نمود که ما در این جا ۱۰ ویژگی را انتخاب نمودیم.




شکل (۱۲): ۱۰ ویژگی انتخاب شده از میان ۱۰۰۰ ویژگی استخراج شده توسط یادگیری عمیق

۲- در روش دوم به واسطه لایه تمام متصل fc7 از شبکه عصبی کانولوشن ۲۰۰۰ ویژگی استخراج شده و سپس از طریق انتخاب ویژگی ۲۰ ویژگی برتر انتخاب می‌گردد.



شکل (۱۳): ۲۰ ویژگی انتخاب شده از میان ۲۰۰۰ ویژگی استخراج شده توسط یادگیری عمیق

۳- در روش دوم به واسطه لایه تمام متصل fc7 از شبکه عصبی کانولوشن ۲۰۰۰ ویژگی استخراج شده و سپس از طریق انتخاب ویژگی، ۵۰ ویژگی برتر انتخاب می‌گردد.



شکل (۱۴): ۵۰ ویژگی انتخاب شده از میان ۲۰۰۰ ویژگی استخراج شده توسط یادگیری عمیق

بعد از استخراج ویژگی های عمیق، از طبقه بندی کننده ها برای تفکیک و تشخیص آریتمی ها استفاده می‌شود. در این بخش ویژگی های عمیق سیگنال به عنوان ورودی به طبقه بندی کننده های KNN, NN, SVM داده شده و با توجه به برجسب یا همان گروه یا آریتمی های مختلف سیگنال که در سایت موجود می باشد، نتایج را مقایسه کرده و صحت را بدست آورده و نتایج را گزارش میشود.

#### ۴-۶- روش ماتریس درهم ریختگی

در بحث با استفاده از روش های دسته بندی، هدف دستیابی به بالاترین دقت و صحت ممکن در دسته بندی و تشخیص دسته ها است. در برخی از مسائل، تشخیص صحیح نمونه های مربوط به یکی از دسته ها برای ما اهمیت بیشتری دارد. به عنوان مثال، تحقیقی را در نظر بگیرید که در آن، هدف شناسایی افراد مبتلا به یک نوع خاص از یک بیماری خطرناک است. فرض کنید برای افرادی که مبتلا به این بیماری هستند، خطر مرگ وجود دارد و جهت رفع این خطر، نیاز به دریافت نوعی داروی خاص دارند. در این شرایط، تشخیص درست بیماران دارای اهمیت بسیار زیادی است.

به این معنا که خطا در تشخیص افراد سالم قابل چشم پوشی است اما برای شناسایی افراد بیمار نمی توان این احتمال را به جان خرید. به عبارت دیگر، انتظار ما تشخیص تمام افراد بیمار است، بدون جا انداختن، حتی اگر فرد سالمی به اشتباه جز افراد بیمار دسته بندی شود. در چنین مواقعی، که دقت و صحت تشخیص یک دسته در مقایسه با دقت و صحت تشخیص کلی، اهمیت بیشتری دارد، مفهوم «ماتریس درهم ریختگی»<sup>۶</sup>، به کمک ما می آید.

بر اساس مثالی که پیش تر بیان شد، فرض کنید تعلق به دسته افراد بیمار را مثبت بودن<sup>۷</sup> و عدم تعلق به این دسته را منفی بودن<sup>۸</sup> در نظر بگیریم. هر نمونه یا فردی در واقعیت، متعلق به یکی از کلاسهای مثبت یا منفی است و از سوی دیگر، از هر الگوریتمی که برای دسته بندی داده ها استفاده شود، در نهایت هر نمونه عضو یکی از این دو «دسته» دسته بندی خواهد شد. بنابراین برای هر نمونه داده، یکی از چهار حالتی که در ادامه بیان شده، ممکن است اتفاق بیفتد.

- نمونه عضو دسته مثبت باشد و عضو همین کلاس تشخیص داده شود (مثبت صحیح)<sup>۱۱</sup>
- نمونه عضو کلاس مثبت باشد و عضو کلاس منفی تشخیص داده شود (منفی کاذب)<sup>۱۱</sup>
- نمونه عضو کلاس منفی باشد و عضو همین کلاس تشخیص داده شود (منفی صحیح)<sup>۱۲</sup>
- و در نهایت، نمونه عضو کلاس منفی باشد و عضو کلاس مثبت تشخیص داده شود (مثبت کاذب)<sup>۱۳</sup>

پس از اجرای الگوریتم دسته بندی، با توجه به توضیحات و تعاریف ذکر شده، می توان عملکرد یک طبقه بند را به کمک جدولی به شکل زیر بررسی کرد.

جدول (۲): ماتریس کامفیوژن

		برچسب پیش بینی شده	
		مثبت (۱)	منفی (۰)
برچسب شناخته شده	مثبت (۱)	TP	FN
	منفی (۰)	FN	TN

این جدول را اصطلاحاً ماتریس درهم ریختگی می گویند. جدول یا ماتریس درهم ریختگی، نتایج حاصل از طبقه بندی را بر اساس اطلاعات واقعی موجود، نمایش می دهد. حال بر اساس این مقادیر می توان معیارهای مختلف ارزیابی دسته بند و اندازه گیری دقت را تعریف کرد. پارامتر صحت<sup>۱۴</sup>، متداول ترین، اساسی ترین و ساده ترین معیار اندازه گیری کیفیت یک دسته بند است و عبارت است از میزان تشخیص صحیح دسته بند در مجموع دو دسته. این پارامتر در واقع نشان گر میزان الگوهایی است که درست تشخیص داده شده اند و بر اساس ماتریس ارائه شده در بالا، به شکل زیر فرموله و تعریف می شود:

(۶)

$$\%Acc = \frac{TP + TN}{TP + TN + FP + FN} \times 100$$

البته، پارامتر صحت معمولاً به صورت درصد بیان می شود. اما پارامترهای دیگری نیز علاوه بر معیار صحت وجود دارند که می توان به سادگی از این ماتریس استخراج کرد. یکی از متداول ترین آن ها، معیار حساسیت<sup>۱۵</sup> است که آن را «نرخ پاسخ های مثبت درست»<sup>۱۶</sup> نیز می گویند. حساسیت به معنی نسبتی از موارد مثبت است که آزمایش آن ها را به درستی به عنوان نمونه مثبت تشخیص داده است. این پارامتر به صورت زیر محاسبه می شود:

(۷)

$$\%Se = \frac{TP}{TP + FN} \times 100$$

در واقع، «حساسیت» همان معیار بحث شده در مورد مثال بالا است. معیاری که مشخص می‌کند دسته‌بندی، به چه اندازه در تشخیص تمام افراد مبتلا به بیماری موفق بوده است. همانگونه که از رابطه فوق مشخص است، تعداد افراد سالمی که توسط دسته‌بندی به اشتباه به عنوان فرد بیمار تشخیص داده شده‌اند، هیچ تاثیری در محاسبه این پارامتر ندارد و در واقع زمانی که پژوهشگر از این پارامتر به عنوان پارامتر ارزیابی برای دسته‌بندی خود استفاده می‌کند، هدفش دستیابی به نهایت صحت در تشخیص نمونه‌های کلاس مثبت است.

در نقطه مقابل این پارامتر، ممکن است در مواقعی صحت تشخیص کلاس منفی حائز اهمیت باشد. از متداول‌ترین پارامترها که معمولاً در کنار حساسیت بررسی می‌شود، پارامتر خاصیت<sup>17</sup>، است که به آن «نرخ پاسخ‌های منفی درست»<sup>18</sup> نیز می‌گویند. خاصیت به معنی نسبتی از موارد منفی است که آزمایش آن‌ها را به درستی به عنوان نمونه منفی تشخیص داده است. این پارامتر به صورت زیر محاسبه می‌شود:


(۸)

$$\%Spe = \frac{TN}{TN + FP} \times 100$$

این دو پارامتر (حساسیت و خاصیت) نیز مشابه معیار صحت، معمولاً به صورت درصد بیان می‌شوند. واضح است که پیش‌بینی عالی، پیش‌بینی است که مقادیر حساسیت و خاصیت مربوط به آن، هر دو صد درصد باشند؛ اما احتمال وقوع این اتفاق در واقعیت بسیار کم است و همیشه یک حداقل خطایی وجود دارد. پارامترهای حساسیت و خاصیت، بنابر ماهیتی که دارند همواره در رقابت با یکدیگر هستند. یعنی افزایش یکی با کاهش دیگری همراه است و برعکس.

##### ۵- نتایج شبیه سازی

الف) روش اول با ۱۰۰۰ ویژگی و ۱۰ انتخاب برتر



شکل (۱۵): صحت طبقه بندی کننده‌ها به صورت نمودار در روش اول (۱۰۰۰ ویژگی و ۱۰ انتخاب برتر)


جدول (۳): نتایج صحت متوسط طبقه بندی کننده‌ها با ۱۰۰۰ ویژگی استخراج شده و ۱۰ ویژگی منتخب

صحت متوسط کل	طبقه بندی کننده
۹۹/۸۶	شبکه عصبی
۸۰/۵۸	ماشین بردار پشتیبان
۹۰/۸۹	K - نزدیکترین همسایه

جدول (۴): صحت و حساسیت کلاس ها در روش اول (۱۰۰۰ ویژگی استخراج شده و ۱۰ ویژگی منتخب)

نوع سیگنال	صحت	حساسیت
سیگنال فرد سالم	۹۸/۰۸	۹۸/۶۱
pvc آریتمی	۹۸/۵۰	۹۸/۳۴
آریتمی apc	۹۸/۶۱	۹۸/۶۸
آریتمی lbbb	۹۹/۶۲	۹۸/۷۸
آریتمی rbbb	۹۹/۷۴	۹۸/۶۵
مجموع	۹۸/۵۸	۹۸/۷۸

(ب) روش دوم با ۲۰۰۰ ویژگی و ۲۰ انتخاب برتر



شکل (۱۶): صحت طبقه بندی کننده ها به صورت نمودار روش دوم (۲۰۰۰ ویژگی و ۲۰ انتخاب برتر)

جدول (۵): نتایج صحت متوسط طبقه بندی کننده ها با ۲۰۰۰ ویژگی استخراج شده و ۲۰ ویژگی منتخب


صحت متوسط کل	طبقه بندی کننده
۲۲/۲۲	شبکه عصبی
۹۷/۳۳	ماشین بردار پشتیبان
۶۱/۱۱	K - نزدیکترین همسایه

جدول (۶): صحت و حساسیت کلاس ها در روش اول (۲۰۰۰ ویژگی استخراج شده و ۲۰ ویژگی منتخب)

نوع سیگنال	صحت	حساسیت
سیگنال فرد سالم	۹۶/۸۲	۹۶/۷۷
pvc آریتمی	۹۷/۲۹	۹۸/۶۱
آریتمی apc	۹۷/۶۱	۹۸/۷۸

۹۸/۷۸	۹۷/۶۱	آریتمی lbbb
۹۸/۶۱	۹۷/۲۹	آریتمی rbbb
۹۸/۳۱	۹۷/۳۳	مجموع

ج) روش سوم با ۲۰۰۰ ویژگی و ۵۰ انتخاب برتر



شکل (۱۷): صحت طبقه بندی کننده‌ها به صورت نمودار روش سوم (۲۰۰۰ ویژگی و ۵۰ انتخاب برتر)

جدول (۷): نتایج صحت متوسط طبقه بندی کننده‌ها با ۲۰۰۰ ویژگی استخراج شده و ۵۰ ویژگی منتخب

صحت متوسط کل	طبقه بندی کننده
۳۸/۸۸	شبکه عصبی
۹۷/۳۳	ماشین بردار پشتیبان
۶۶/۶۷	K - نزدیکترین همسایه

جدول (۸): صحت و حساسیت کلاس‌ها در روش اول (۲۰۰۰ ویژگی استخراج شده و ۵۰ ویژگی منتخب)

حساسیت	صحت	نوع سیگنال
۹۶/۷۷	۹۶/۸۲	سیگنال فرد سالم
۹۸/۶۱	۹۷/۲۹	pvc آریتمی
۹۸/۷۸	۹۷/۶۱	آریتمی apc
۹۸/۷۸	۹۷/۶۱	آریتمی lbbb
۹۸/۶۱	۹۷/۲۹	آریتمی rbbb
۹۸/۳۱	۹۷/۳۳	مجموع

همانگونه از نتایج ملاحظه می‌کنید به این نتیجه می‌توان رسید که روش پیشنهادی برای تشخیص آریتمی های قلبی روشی مناسب می‌باشد.



با توجه به استفاده از ویژگی های عمیق بدون دخالت دست سیستم را یک سیستم کاملا خودکار می توان در نظر گرفت. به دلیل زمان پردازش پایین می توان سیستم را یک سیستم تشخیصی زمان حقیقی دانست. با توجه به جدول ۳ تا ۸ طبقه بندی کننده SVM از روش ۱۰۰۰ ویژگی با ۱۰ ویژگی منتخب (مربوط به لایه تماما متصل fc8) از سایر طبقه بندی کننده ها داری نتیجه بهتری شده است و نتایج تک تک گروه آریتمی ها برای SVM در جدول ۳ الی ۸ گزارش کرده ایم.

#### ۶- نتیجه گیری

در این مقاله سیگنال های دارای آریتمی از سایت فیزیوت که دارای سیگنال با برچسب معتبر بوده و توسط پزشک متخصص مشخص شده است، دانلود گردید. سپس ویژگی های عمیق با استفاده از شبکه عصبی عمیق بر مبنای معماری AlexNet استخراج گردید و توسط انتخاب ویژگی و وزن دهی TFCRF ویژگی های مناسب انتخاب شد. در نهایت با استفاده از سه طبقه بندی کننده متداول، آریتمی های قلبی با استفاده از سیگنال قلبی طبقه بندی شد. نتایج سه طبقه بندی کننده در جدول ۳ الی ۸ نمایش داده شده است. همانگونه که مشخص است صحت طبقه بندی کننده SVM از روش ۱۰۰۰ ویژگی با ۱۰ ویژگی منتخب از سایر طبقه بندی کننده ها بالاتر است و به عنوان طبقه بندی کننده برگزیده انتخاب می شود. با توجه به گزارشات و نتایج می توان به این نتیجه رسید که روش پیشنهادی برای تشخیص آریتمی ها دارای قابلیت اطمینان است و می توان آن را انتخاب نمود.

#### References

##### مراجع

- [1] R.J. Martis, U. Rajendra Acharya and C.M. Lim, "ECG Beat Classification Using PCA, LDA, ICA and Discrete Wavelet Transform", *Biomedical Signal Processing and Control*, vol. 8, pp. 437-448, 2013.
- [2] U.R. Acharya, H. Fujita, V.K. Sudarshan, S.L. Oh, M. Adam, and J.E.W. Koh, "Automated detection and localization of myocardial infarction using electrocardiogram: A comparative study of different leads", *Knowledge-Based Systems*, vol. 99, pp. 146-156, 2016.
- [3] A. Lal, P. Kumar and S. Halder, "Heartbeat Classification Based on Deep Convolutional Neural Network", *2023 International Conference on Networking and Communications (ICNWC)*, Chennai, India, 2023, pp. 1-4, doi: 10.1109/ICNWC57852.2023.10127341.
- [4] E.D. Beyli, "Combining recurrent neural networks with eigenvector methods for classification of ECG beats", *Digital Signal Processing*, vol. 19, issue 2, pp. 320-329, 2009.
- [5] S. Chauhan and L. Vig, "Anomaly detection in ECG time signals via deep long short-term memory networks", *2015 IEEE International Conference on Data Science and Advanced Analytics (DSAA)*, Paris, France, 2015, pp. 1-7, doi: 10.1109/DSAA.2015.7344872.
- [6] M.K. Das, S. Ari, "ECG Beats Classification Using Mixture of Features", *International Scholarly Research Notices*, vol. 2014, p. 14, 2019.
- [7] C. Chen, Y. Lin, S. Lee, W. Tsai, T. Huang, Y. Liu, M. Cheng, C. Dai, "Automated ECG classification based on 1D deep learning network Methods", *Methods*, vol. 202, pp. 127-135, Jun 2022.
- [8] N. Ö. Özcan and F. Gürgen, "Fuzzy Support Vector Machines for ECG Arrhythmia Detection," *2010 20th International Conference on Pattern Recognition*, Istanbul, Turkey, 2010, pp. 2973-2976, doi: 10.1109/ICPR.2010.728.
- [9] R.D. Labati, E. Munoz, V. Piuri and R. Sassi, "Deep-ECG: Convolutional Neural Networks for ECG biometric recognition", *Pattern Recognition Letters*, vol. 126, pp. 78-85, Sep. 2019.
- [10] A. Sellami, H. Hwang, "A robust deep convolutional neural network with batch-weighted loss for heartbeat

classification”, *Expert Systems with Applications*, Vol. 122, pp. 75–84, May 2019.

- [11] J. Park, K. Lee and K. Kang, “Arrhythmia detection from heartbeat using k-nearest neighbor classifier”, *2013 IEEE International Conference on Bioinformatics and Biomedicine*, Shanghai, China, 2013, pp. 15-22, doi: 10.1109/BIBM.2013.6732594.
- [12] P. Pławiak, “Novel Genetic Ensembles of Classifiers Applied to Myocardium Dysfunction Recognition Based on ECG Signals”, *Swarm and Evolutionary Computation*, vol. 39, pp. 192-208, April 2018.
- [13] Ö. Yildirim, “A novel wavelet sequences based on deep bidirectional LSTM network model for ECG signal classification”, *Computers in Biology and Medicine*, vol. 96, pp. 189-202, May 2018.

زیر نویس‌ها:

- <sup>1</sup> Support vector machine
- <sup>2</sup> K-near neighbors
- <sup>3</sup> feature
- <sup>4</sup> CNN
- <sup>5</sup> feature identifier
- <sup>6</sup> Confusion Matrix
- <sup>7</sup> Positive
- <sup>8</sup> Negative
- <sup>9</sup> Class
- <sup>10</sup> True Positive
- <sup>11</sup> False Negative
- <sup>12</sup> True Negative
- <sup>13</sup> False Positive
- <sup>14</sup> Accuracy
- <sup>15</sup> Sensitivity
- <sup>16</sup> True Positive Rate
- <sup>17</sup> Specificity
- <sup>18</sup> True Negative Rate