



Prediction of Sudden Cardiac Death using Time-Frequency Analysis of Electrocardiogram Signal

Danesh Jablo, Fatemeh¹ / Danandeh Hesar, Hamed^{2*}

¹ - M.Sc., Faculty of Biomedical Engineering, Sahand University of Technology, Tabriz, Iran

² - Assistant Professor, Faculty of Biomedical Engineering, Sahand University of Technology, Tabriz, Iran

ARTICLE INFO

DOI: 10.22041/ijbme.2024.2025664.1892

Received: 29 March 2024

Revised: 18/6/2024 – 27/7/2024

Accepted: 6 August 2024

KEYWORDS

Sudden Cardiac Death
Electrocardiogram Signal
Empirical Mode
Decomposition
Nonlinear Feature
Extraction

ABSTRACT

Sudden cardiac death (SCD) is a significant cardiovascular issue that affects approximately 3 million individuals globally each year, often occurring without any prior noticeable symptoms. The precise causes of SCD remain unclear, although ventricular fibrillation is thought to play a crucial role in its pathophysiology. Since symptoms usually appear only an hour before the event, timely prediction is essential for effective cardiac resuscitation. This study aims to predict SCD using time-frequency analysis of ECG signals. Two online datasets were utilized: the Sudden Cardiac Death Holter dataset and the MIT-BIH Normal Sinus Rhythm dataset. The proposed method involves segmenting the 60-minute interval prior to ventricular fibrillation into one-minute segments, which are then decomposed into time-frequency sub-bands using empirical mode decomposition (EMD). Nonlinear features are extracted from these decomposed signals, followed by classification using support vector machines (SVM) and K-nearest neighbors (KNN). To enhance classification accuracy, two statistical feature selection techniques, T-test and ANOVA, were employed. Results indicate that using the ANOVA feature selection method with SVM and KNN algorithms achieves high accuracy in predicting SCD. Specifically, the average accuracy rates for the 60 minutes preceding SCD were 93.51% for ANOVA-SVM and 93% for ANOVA-KNN. With T-test feature selection, the average accuracy rates were 93.29% for SVM and 93.41% for KNN. These findings demonstrate the promising performance of the proposed approach in predicting SCD.

*Corresponding Author


Address: Faculty of Biomedical Engineering, Sahand University of Technology, Tabriz, Iran

Postal Code: 51335-1996

E-Mail: danandeh@sut.ac.ir

Tel: +98-41-33458413





پیش‌بینی مرگ ناگهانی قلبی با استفاده از تحلیل زمان-فرکانسی سیگنال الکتروکاردیوگرام

دانش جابلو، فاطمه^۱ / داننده حصار، حامد^{۲*}

^۱ - کارشناسی ارشد، گروه بیوالکتریک، دانشکده‌ی مهندسی پزشکی، دانشگاه صنعتی سهند، تبریز، ایران

^۲ - استادیار، گروه بیوالکتریک، دانشکده‌ی مهندسی پزشکی، دانشگاه صنعتی سهند، تبریز، ایران

مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/ijbme.2024.2025664.1892

پذیرش: ۱۶ مرداد ۱۴۰۳

بازنگری: ۱۴۰۳/۳/۲۹ - ۱۴۰۳/۵/۶

ثبت در سامانه: ۱۰ فروردین ۱۴۰۳

چکیده

واژه‌های کلیدی

مرگ ناگهانی قلبی (SCD) یک عارضه‌ی مهم قلبی عروقی است که سالانه حدود ۳ میلیون نفر را در سراسر جهان تحت تاثیر قرار داده و اغلب بدون علائم قابل مشاهده‌ی قلبی رخ می‌دهد. علل دقیق SCD هنوز مشخص نیست، اگر چه فیبریلاسیون بطنی به عنوان یک عامل اصلی در پاتوفیزیولوژی آن شناخته می‌شود. با توجه به این که علائم معمولاً تنها یک ساعت قبل از وقوع حادثه ظاهر می‌شوند، پیش‌بینی به موقع برای احیای موثر قلبی ضروری است. این مطالعه به منظور پیش‌بینی SCD از تحلیل زمان-فرکانس سیگنال‌های ECG انجام شده است. در این پژوهش از دو مجموعه‌ی داده‌ی آنلاین هولتر مرگ ناگهانی قلبی و ریتم سینوسی نرمال MIT-BIH استفاده شده است. روش پیشنهادی شامل تقسیم بازه‌ی ۶۰ دقیقه‌ای قبل از فیبریلاسیون بطنی به بخش‌های ۱ دقیقه‌ای است که سپس با استفاده از تجزیه‌ی حالت تجربی (EMD) به باندهای زیرزمان-فرکانس تفکیک شده‌اند. ویژگی‌های غیرخطی از این سیگنال‌های تجزیه شده استخراج گردیده و سپس طبقه‌بندی با استفاده از ماشین‌های بردار پشتیبان (SVM) و k نزدیک‌ترین همسایگان (KNN) انجام شده است. برای بهبود صحت، دو تکنیک انتخاب ویژگی آماری T-test و ANOVA به کار گرفته شده است. نتایج نشان می‌دهد که استفاده از روش انتخاب ویژگی ANOVA همراه با الگوریتم‌های SVM و KNN به صحت بالایی در پیش‌بینی SCD دست یافته است. به طور خاص صحت متوسط در ۶۰ دقیقه قبل از SCD برای روش‌های ANOVA-SVM و ANOVA-KNN به ترتیب برابر با ۹۳/۵۱٪ و ۹۳٪ است. با استفاده از انتخاب ویژگی T-test صحت متوسط برای روش‌های SVM و KNN به ترتیب برابر با ۹۳/۲۹٪ و ۹۳/۴۱٪ است. این یافته‌ها عمل‌کرد امیدوارکننده‌ی روش پیشنهادی در پیش‌بینی SCD را نشان می‌دهد.

مرگ ناگهانی قلبی

سیگنال ECG

تجزیه‌ی حالت تجربی

استخراج ویژگی‌های غیرخطی

*نویسنده‌ی مسئول

نشانی: گروه بیوالکتریک، دانشکده‌ی مهندسی پزشکی، دانشگاه صنعتی سهند، تبریز، ایران

تلفن: ۰۹۸-۴۱-۳۳۴۵۸۴۱۳

پست الکترونیک: danandeh@sut.ac.ir

کد پستی: ۵۱۳۳۵-۱۹۹۶



۱- مقدمه

قلبی است. بنابراین پیش‌بینی زود هنگام خطر SCD غیرمنتظره در فردی که VF را تجربه می‌کند، برای درمان به موقع و افزایش بقا بسیار حائز اهمیت است. در مطالعات مختلف از تحلیل سیگنال ECG یا سیگنال HRV^۴ برای تشخیص SCD استفاده شده است. در مقالات [۵، ۷، ۸] برای تشخیص SCD، سیگنال HRV حاصل از تشخیص قله‌های R سیگنال ECG مورد بررسی قرار گرفته است. هم‌چنین در این مطالعات بازه‌های مختلفی برای بررسی SCD مورد استفاده قرار گرفته است. در پژوهش [۵] سیگنال HRV ۱ دقیقه‌ای از سیگنال ECG، ۶ دقیقه قبل از وقوع SCD استخراج شده است. ویژگی‌های حوزه‌ی فرکانس و ویژگی‌های غیرخطی از سیگنال HRV استخراج شده و سپس با استفاده از روش ANOVA بهترین ویژگی‌ها برای تمایز بین دو کلاس انتخاب شده است. نهایتاً با استفاده از طبقه‌بندهای K-نزدیک‌ترین همسایگی (KNN)، ماشین بردار پشتیبان (SVM)، درخت تصمیم (DT) و بیز ساده افراد سالم و افراد معرض خطر طبقه‌بندی شده‌اند. در مقاله‌ی [۷] سیگنال‌های ECG مربوط به چهار گروه شامل بیماری کرونری^۵ (CAD)، نارسایی احتقانی قلب^۶ (CHF)، افراد نرمال^۷ (NSR) و افراد SCD به مدت یک ساعت انتخاب شده است. سیگنال‌های گروه SCD به مدت یک ساعت قبل از شروع VF در نظر گرفته شده است. در این کار برای اولین بار از بازنمایی فرکانس-زمانی سیگنال‌های HRV توسط تبدیل S^۸ تممیم‌یافته^۸ استفاده شده است. سپس طبقه‌بندی افراد سالم و در معرض خطر با استفاده از طبقه‌بند SVM و DT انجام شده است. در مقاله‌ی [۸] از سیگنال‌های ECG در حدود ۱۴ دقیقه قبل از شروع VF استفاده شده است. در ابتدا تبدیل موجک گسسته^۹ (DWT) با موجک DB6 برای حذف نویز سیگنال‌های ECG مورد استفاده قرار گرفته و سپس سیگنال‌های HRV با استفاده از روش تجزیه‌ی حالت تجربی گروهی^{۱۰} (EEMD) به مولفه‌های مختلف تجزیه شده و از آن‌ها ویژگی‌های مختلف آنتروپی جهت طبقه‌بندی افراد سالم از افراد مبتلا به SCD استخراج شده است. در مقالات [۹-۱۴] از سیگنال ECG برای تشخیص SCD استفاده شده است. در هر یک از این مطالعات دقایق مختلفی قبل از وقوع VF برای تشخیص SCD استخراج و بررسی شده است. در پژوهش [۹] در ابتدا از روش تجزیه‌ی حالت تجربی

مرگ ناگهانی قلبی^۱ (SCD) یک عارضه‌ی قلبی و عروقی است که سالانه چندین میلیون نفر را در سراسر جهان بدون هیچ‌گونه علائم قابل تشخیص خارجی تحت تاثیر قرار می‌دهد [۱]. فیبریلاسیون بطنی^۲ (VF) علت اصلی مرگ ناگهانی قلبی در نظر گرفته می‌شود. مرگ ناگهانی قلبی، مرگ فردی را توصیف می‌کند که با بروز اولین علائم، بر اثر بیماری‌های قلبی شناخته شده یا ناشناخته، جان خود را از دست می‌دهد [۲]. مرگ ناگهانی قلبی با حمله‌ی قلبی متفاوت است. در حالی که حمله‌ی قلبی به عنوان مشکل عروقی توصیف می‌شود، مرگ ناگهانی قلبی، بیش‌تر یک مشکل الکتروفیزیولوژیکی است که از عمل‌کرد موثر قلب جلوگیری می‌کند. حملات قلبی می‌تواند منجر به مرگ ناگهانی قلبی شود، اما دلایل دیگری مانند ناهنجاری مادرزادی، نارسایی شدید قلبی، برق‌گرفتگی و مصرف بیش از حد دارو نیز در این زمینه دخیل است. مرگ ناگهانی قلبی باعث توقف ناگهانی و غیرمنتظره‌ی عمل‌کرد قلب و منجر به کمبود اکسیژن و از دست دادن سطح هوشیاری در عرض یک دقیقه می‌شود. زمانی که SCD خارج از بیمارستان رخ دهد، تنها ۱-۲٪ از بیماران زنده خواهند ماند [۳]. با استفاده از تجهیزات پزشکی از جمله دستگاه الکتروشوک می‌توان درصد کمی از مرگومیر را کاهش داد. مرگ ناگهانی قلبی به طور کلی در عرض یک ساعت پس از شروع علائم رخ می‌دهد [۴]. هر گونه انحراف از ریتم طبیعی قلب نشان دهنده‌ی اختلال در عمل‌کرد پمپاژ طبیعی قلب است. در اغلب موارد، آریتمی‌های قلبی مانند فیبریلاسیون بطنی (VF) و تاکی‌کاردی بطنی^۳ (VT) پیش‌رخداد SCD هستند [۵]. فیبریلاسیون بطنی تقریباً در ۲۰ درصد موارد SCD اتفاق می‌افتد. میزان مرگومیر ناشی از بیماری‌های قلبی در چند دهه‌ی اخیر کاهش یافته اما SCD هنوز به عنوان پیشگام علت مرگومیر در ایالات متحده‌ی آمریکا و هم‌چنین سایر کشورها گزارش شده است [۳]. سالانه حدود ۳۵۰ هزار نفر در اروپا و بین ۳۰۰۰۰۰ تا ۴۰۰۰۰۰ نفر در ایالات متحده به طور ناگهانی و غیرمنتظره جان خود را از دست می‌دهند [۶]. از آن‌جا که شروع علائم تقریباً یک ساعت قبل از مرگ ناگهانی ظاهر می‌شود، تشخیص زود هنگام SCD یک مساله‌ی حیاتی برای پزشکان جهت انجام احیای موفق فعالیت

^۶ Congestive Heart Failure^۷ Normal Sinus Rythm^۸ Generalized S-transform^۹ Discrete Wavelet Transform^{۱۰} Ensemble Empirical Mode Decomposition^۱ Sudden Cardiac Death^۲ Ventricular Fibrillation^۳ Ventricular Tachycardia^۴ Heart Variability Rate^۵ Coronary Artery Disease

باند فرکانس محاسبه شده است. در مرحله‌ی سوم مقادیر HI برای هر باند با استفاده از روش آماری ANOVA یک‌طرفه برای تعیین متمایزترین ویژگی‌ها برای تشخیص SCD ارزیابی شده است. در مرحله‌ی چهارم، این ویژگی‌های انتخاب شده با استفاده از طبقه‌بند شبکه‌ی عصبی احتمالی تقویت شده^{۱۲} (EPNN) به منظور پیش‌بینی SCD به صورت خودکار طبقه‌بندی شده است. در مطالعه‌ی [۱۳] روشی برای پیش‌بینی SCD با استفاده از تبدیل موجک گسسته (DWT) و نگاشت حفظ مکانی^{۱۳} (LPP) پیشنهاد شده است. پس از اعمال DWT به سیگنال ECG و استخراج ضرایب موجک، از LPP برای کاهش ابعاد این ضرایب استفاده گردیده است. این ضرایب به عنوان بردار ویژگی به طبقه‌بندهای مختلف داده شده است. روش پیشنهادی این مقاله روی ۱۴ دقیقه قبل از SCD مورد بررسی قرار گرفته است. در مقاله‌ی [۱۴] ۳۰ دقیقه قبل از SCD مورد استفاده قرار گرفته است. در این مقاله از یک روش مبتنی بر تجزیه‌ی حالت تجربی مجموعه‌ای مکمل^{۱۴} (CEEMD) به منظور تجزیه‌ی سیگنال ECG به مولفه‌های زمانی-فرکانسی و از یک شبکه‌ی عصبی کانولوشنی^{۱۵} (CNN) برای طبقه‌بندی استفاده گردیده است.

پیش‌بینی زودهنگام SCD برای درمان به موقع و افزایش بقا از اهمیت بالایی برخوردار است. هر چه بررسی رخداد SCD زودتر صورت گیرد، کمک بیش‌تری به پزشک برای انجام احیای موفق قلبی خواهد کرد. تا کنون تنها در مطالعات محدودی به بازه‌ی زمانی ۶۰ دقیقه قبل از SCD پرداخته شده است. از آن‌جا که این بازه‌ی زمانی فرصت کافی را به پزشکان برای انجام درمان به موقع می‌دهد، در این مقاله به بررسی این بازه پرداخته شده است. هم‌چنین در این بررسی با استفاده‌ی صرف از سیگنال ECG و بدون استفاده از سیگنال HRV سعی شده است تا صحت‌های بالاتری در پیش‌بینی SCD به دست آید.

در این مقاله یک رویکرد جدید و کارآمد به منظور پیش‌بینی مرگ ناگهانی قلبی با استفاده از ویژگی‌های سیگنال‌های ECG ارائه گردیده است. در رویکرد پیشنهادی از سیگنال ECG، تبدیل حالت تجربی^{۱۶} (EMD) گرفته شده و سپس ویژگی‌های

(EMD) برای تحلیل سیگنال ECG به مجموعه‌ای از باندهای فرکانسی با توجه به اطلاعات موجود در سیگنال ECG استفاده شده است. فقط ۲۵ دقیقه از سیگنال ECG قبل از وقوع SCD مورد استفاده قرار گرفته است. شاخص‌های تشخیصی ابعاد فراکتال^۱ (FD) و آنتروپی از باندهای فرکانسی به دست آمده به منظور پیش‌بینی SCD به کار گرفته شده است. سپس انتخاب ویژگی با استفاده از روش آماری ANOVA انجام شده است. ویژگی‌های انتخاب شده با استفاده از یک شبکه‌ی عصبی چندلایه‌ی پرسپترون^۲ (MLP-NN) طبقه‌بندی شده است. در مقاله‌ی [۱۰] ۶۰ دقیقه قبل از SCD مورد بررسی قرار گرفته است. هر قطعه‌ی ۱ دقیقه‌ای از سیگنال‌های ECG توسط پنج ویژگی FD تجزیه و تحلیل شده است. در مرحله‌ی بعد، مقادیر FD تخمین زده شده با استفاده از تجزیه و تحلیل واریانس به نام کروسکال والیس^۳ ارزیابی شده است. در نهایت مقادیر الگوریتم‌های FD انتخاب شده به عنوان ورودی در یک سیستم منطق فازی^۴ (FLS) برای تشخیص رخداد SCD به صورت خودکار استفاده شده است. دقت کل به دست آمده ۹۱/۵۸٪ است. در مقاله‌ی [۱۱] از ویژگی‌های غیرخطی مانند ابعاد فراکتال، توان هرست^۵ (H)، تجزیه و تحلیل نوسانات کاهش یافته^۶ (DFA)، ابعاد همبستگی^۷ (CD)، آنتروپی تقریبی^۸ (ApproxEnt) و آنتروپی نمونه^۹ (SampEnt) از سیگنال‌های ECG مربوط به ۴ دقیقه قبل از وقوع SCD استفاده شده است. در مجموع ۱۸ ویژگی غیرخطی با استفاده از این روش‌ها استخراج شده است. در این کار از آزمون t-test برای رتبه‌بندی ویژگی‌ها استفاده شده است. در نهایت از طبقه‌بندهای DT، KNN و SVM برای تمایز ECG بین افراد نرمال و افراد در معرض خطر ابتلا به SCD استفاده شده است. در پژوهش [۱۲] ویژگی‌های مختلف از تنها ۲۰ دقیقه‌ی اول سیگنال‌های ECG قبل از شروع SCD استخراج گردیده است. در مرحله‌ی اول با استفاده از تبدیل بستی موجک^{۱۰} (WPT) هر بازه‌ی ۱ دقیقه‌ای از سیگنال‌های ECG با توجه به سطح تجزیه به مجموعه‌ی سیگنال‌ها با باندهای فرکانسی مختلف تجزیه شده است. در مرحله‌ی دوم مقدار شاخص هیگوجی^{۱۱} (HI) برای هر

^۱ Sample Entropy

^۲ Wavelet Packet Transform

^۳ Higuchi Index

^۴ Enhanced Probabilistic Neural Network

^۵ Locality Preserving Projection

^۶ Complete Ensemble Empirical Mode Decomposition

^۷ Convolutional Neural Network

^۸ Empirical Mode Decomposition

^۱ Fractal Dimensions

^۲ Multi-Layer Perceptron Neural Network

^۳ Kruskal-Wallis

^۴ Fuzzy Logic System

^۵ Hurst's Exponent

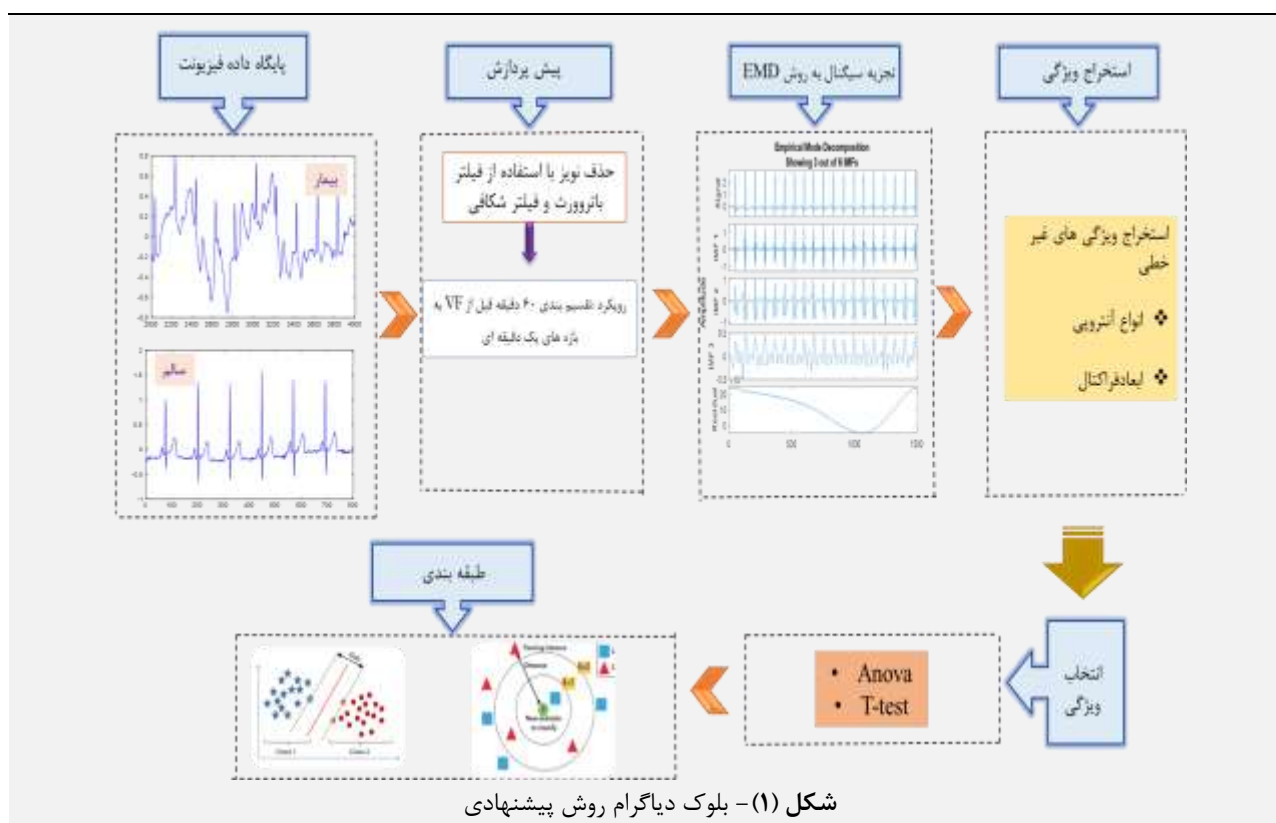
^۶ Detrended Fluctuation Analysis

^۷ Correlation Dimension

^۸ Approximate Entropy

۶۰ دقیقه قبل از SCD را مورد بررسی قرار داده است. به علاوه در این مقاله با استفاده‌ی صرف از سیگنال ECG و بدون استفاده از سیگنال HRV سعی شده است تا صحت‌های بالاتری در پیش‌بینی SCD به دست آید. یک نمودار بلوکی از طرح پیشنهادی در شکل (۱) به نمایش گذاشته شده است. در ادامه‌ی مقاله در بخش ۲-۲ در مورد روش پیشنهادی به تفصیل صحبت شده، در بخش ۳ به ارزیابی نتایج حاصل از به کارگیری روش پرداخته شده و در بخش ۴ جمع‌بندی و مقایسه‌ی این روش با سایر روش‌های رقیب انجام شده است.

غیرخطی از آن استخراج شده است. ویژگی‌های استخراج شده با روش آماری t-test و ANOVA برای تعیین متمایزترین مقادیر جهت تشخیص SCD ارزیابی شده است. برای طبقه‌بندی افراد سالم و افرادی که دچار مرگ ناگهانی قلبی شده‌اند، از طبقه‌بندهای SVM و KNN استفاده شده است. نوآوری این مقاله، استفاده از تجزیه‌ی حالت تجربی روی سیگنال‌های ECG، استخراج ویژگی‌های غیرخطی از مولفه‌های ذاتی آن و انتخاب ویژگی برای پیش‌بینی بهتر مرگ ناگهانی قلبی است. هم‌چنین این مقاله جزء معدود تحقیقاتی بوده که



فرد سالم است. این پایگاه داده حاوی ثبت‌های مربوط به ۵ مرد در بازه‌ی سنی ۲۶ تا ۴۵ سال و ۱۳ زن در بازه‌ی سنی ۲۰ تا ۵۰ سال است. فرکانس نمونه‌برداری آن نیز ۱۲۸ هرتز است. تعداد ۱۸ فرد سالم توسط آزمایشگاه آریتمی در بیمارستان بث‌بوستون اسرائیل انتخاب شده که تیمی از متخصصان قلب و عروق تایید کرده‌اند که تمام بیماران تحت مطالعه دارای ضربان قلب طبیعی و بدون عوارض پاتولوژیک هستند.

۲-۲- پیش پردازش

در این مرحله چندین عملیات صورت گرفته است. در مرحله‌ی اول برای هماهنگی با داده‌های NSR، مطابق با شیوه‌ی اتخاذ شده در مطالعات پیشین، فرکانس نمونه‌برداری داده‌های SCD

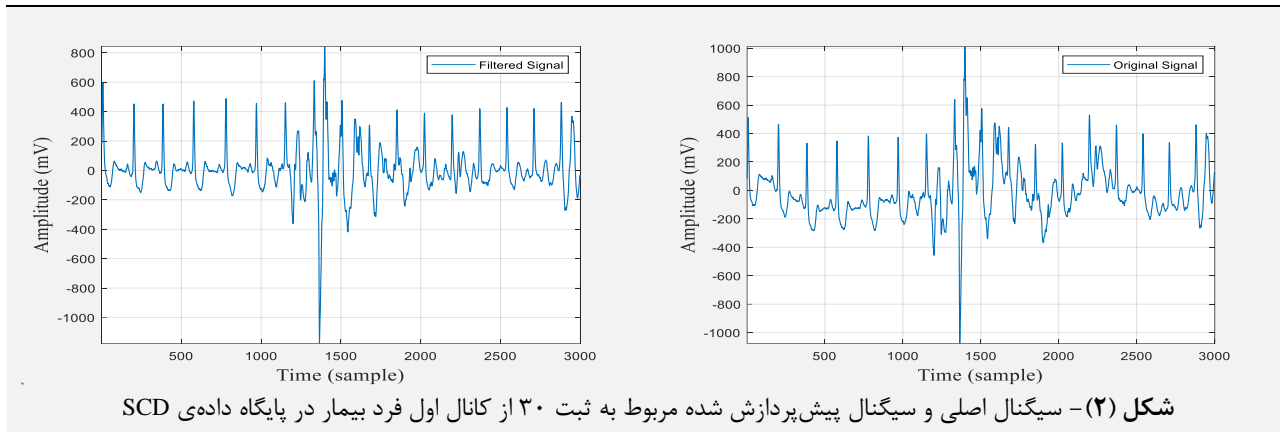
۲- مواد و روش‌ها

۲-۱- پایگاه داده

در این مطالعه برای تشخیص سیگنال‌های ECG مشکوک به SCD از دو پایگاه SCD Holter [۱۵] و NSR MIT-BIH [۱۶] استفاده شده است. سیگنال‌های بیماران SCD از پایگاه داده‌ی SCD Holter و سیگنال‌های افراد سالم از پایگاه داده‌ی NSR انتخاب شده است. پایگاه داده‌ی SCD شامل ۲۳ بیمار است که اکثراً مشکوک به SCD هستند. ثبت‌های موجود در این پایگاه، دوکاناله و مربوط به ۱۵ مرد در بازه‌ی سنی ۱۷ تا ۸۰ و ۸ زن در بازه‌ی سنی ۶۷ تا ۸۲ سال است. سه ثبت با شماره‌های ۴۰، ۴۲ و ۴۹ دارای زمان شروع SCD نبوده و به همین دلیل در مطالعات قابل استفاده نیست. پایگاه داده‌ی NSR نیز شامل ۱۸

قبل از زمان ارائه شده در نظر گرفته شده و به قطعه‌های ۷۶۸۰ نمونه‌ای تقسیم شده است. نمونه‌ای از سیگنال پیش‌پردازش شده در شکل (۲) نشان داده شده است. این سیگنال مربوط به لید اول ثبت ۳۰ متعلق به پایگاه داده‌ی SCD است و یک قطعه‌ی ۱ دقیقه‌ای پیش از شروع VF پس از پیش‌پردازش را نشان می‌دهد. از آن‌جا که پایگاه داده‌ی نرمال شروع VF ندارد، در نتیجه ۶۰ دقیقه به صورت دلخواه از کل ثبت انتخاب شده و به قطعه‌های ۱ دقیقه‌ای تقسیم شده است.

از ۲۵۰ به ۱۲۸ هرتز تغییر یافته است. در مرحله‌ی دوم، از یک فیلتر باترورث بالاگذر مرتبه‌ی ۳ با باند عبور ۱ هرتز برای حذف نویز فرکانس پایین خط زمینه استفاده شده است. سپس از یک فیلتر شکافی^۱ با فرکانس ۵۰ هرتز و طول باند تضعیف ۱ هرتز برای حذف نویز برق شهر استفاده شده است. در مرحله‌ی سوم با توجه به شروع VF، برای هر ثبت موجود در SCD ۶۰ دقیقه قبل از آن در نظر گرفته شده و به قطعه‌های ۱ دقیقه‌ای تقسیم شده است. به عبارت دیگر ۶۰×۶۰×۱۲۸ برابر با ۴۶۰۸۰۰ نمونه



۴- محاسبه‌ی مقدار میانگین پوش بالا و پایین منحنی

$$m(t) = \frac{e_{max}(t) + e_{min}(t)}{2} \quad (1)$$

۵- تفاضل مقدار میانگین محاسبه شده از سیگنال $x(t)$

$$h(t) = x(t) - m(t) \quad (2)$$

اگر $h(t)$ به دست آمده، دو شرط ذکر شده برای تعیین توابع حالت ذاتی را برآورده کند، به عنوان اولین تابع حالت ذاتی در نظر گرفته شده، مقادیر n و $h(t)$ به ترتیب به صورت $n=n+1$ و $h(t)=imf_n(t)$ قرار گرفته و الگوریتم به مرحله‌ی بعدی می‌رود. در غیر این صورت الگوریتم پایان می‌یابد.
۶- مقدار باقی‌مانده طبق رابطه‌ی زیر محاسبه می‌شود.

$$r(t) = x(t) - imf_n(t) \quad (3)$$

اگر $r(t)$ یک تابع یک‌نواخت باشد، فرایند غربال‌گری پایان می‌یابد. در غیر این صورت مراحل ۲ تا ۶ تکرار می‌شود. تابع $x(t)$ را می‌توان در نهایت به صورت زیر بیان کرد که یک ترکیب خطی از اجزای توابع حالت ذاتی و بخش باقی‌مانده است.

۲-۳ تجزیه‌ی سیگنال ECG با استفاده از تجزیه‌ی

حالت تجربی

تجزیه‌ی حالت تجربی (EMD) یک فرایند تکراری است که در آن یک سیگنال به مجموعه‌ای از مولفه‌های ذاتی یا توابع حالت ذاتی^۲ (IMF) تجزیه می‌شود [۹]. هر تابع حالت ذاتی در این روش تجزیه باید دو شرط زیر را برآورده کند [۱۷].
۱- تعداد نقاط اکسترمم و عبور از صفر آن باید یکسان یا حداکثر یک واحد تفاوت داشته باشد
۲- در هر نقطه مقدار میانگین محاسبه شده از پوش بالا و پایین منحنی باید صفر باشد
برای یک سیگنال ورودی $x(t)$ ، توابع حالت ذاتی طبق مراحل زیر از سیگنال ورودی ایجاد می‌شود.
۱- تنظیم مقادیر اولیه

$$r(t) = x(t), n = 0$$

۲- تعیین تمام نقاط بیشینه و کمینه‌ی محلی در $r(t)$
۳- به دست آوردن پوش بالایی منحنی $e_{max}(t)$ و پوش پایینی منحنی $e_{min}(t)$ از طریق درون‌یابی اسپلاین مکعبی بین تمام نقاط بیشینه و کمینه‌ی محلی

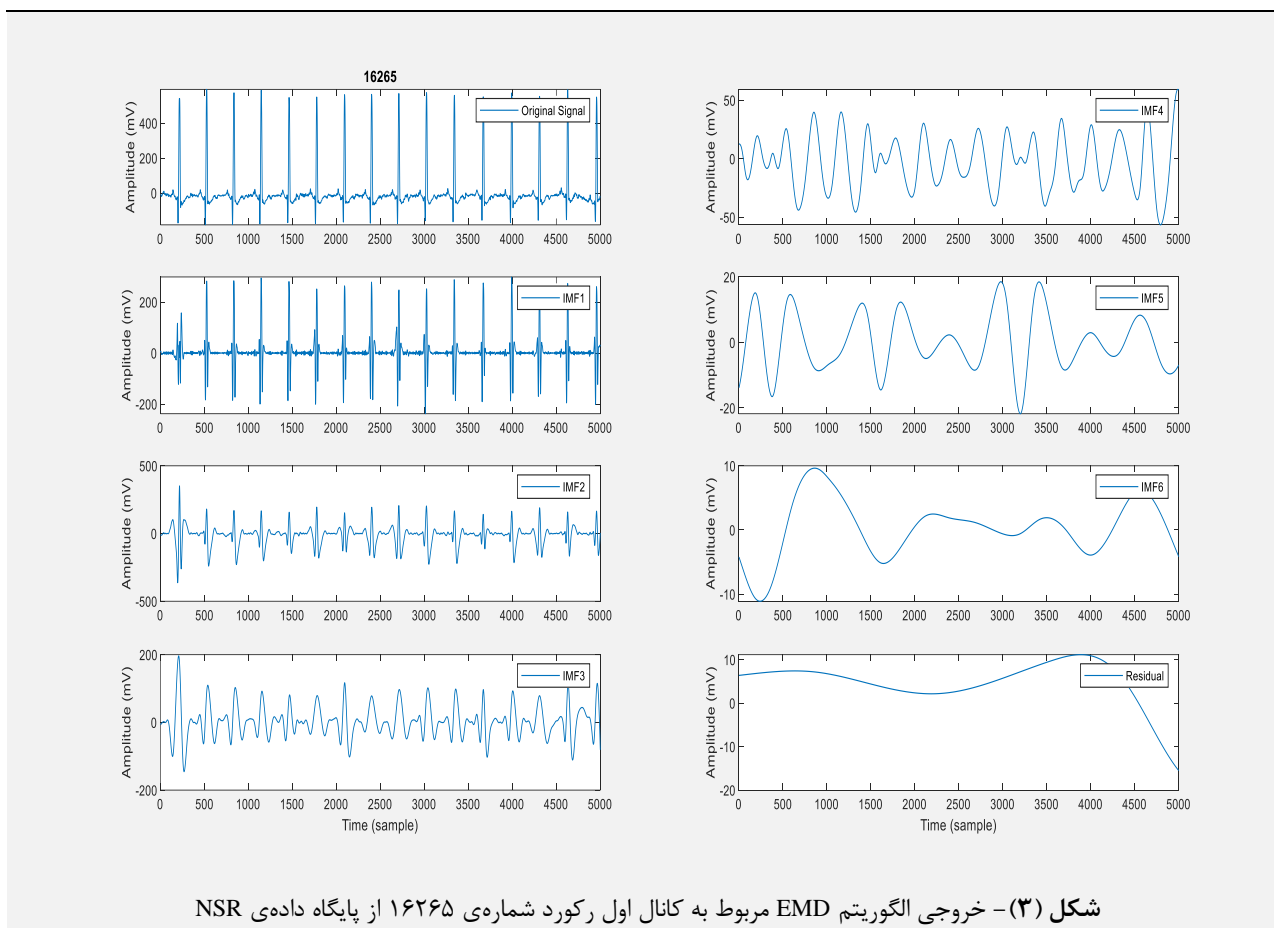
^۱ Intrinsic Mode Function

^۱ Notch Filter

باقی‌مانده دارای نوسانات بسیار ناچیزی بوده که اطلاعات زیادی برای استخراج ویژگی نخواهد داشت. در شکل (۳) نتیجه‌ی اعمال تبدیل EMD برای یک نمونه‌ی سیگنال ECG نشان داده شده است. برای نمایش بهتر در این شکل تنها ۳ عدد IMF به همراه باقی‌مانده رسم شده است.

$$x(t) = \sum_{i=1}^n imf_n(t) + r(t) \quad (۴)$$

در این مقاله با توجه به فرکانس نمونه‌برداری، به صورت تجربی مشاهده شده که با استخراج ۶ تابع حالت ذاتی اول، سیگنال



شکل (۳) - خروجی الگوریتم EMD مربوط به کانال اول رکورد شماره‌ی ۱۶۲۶۵ از پایگاه داده‌ی NSR

رفتارهای غیرخطی در سیگنال ECG می‌شوند. هم‌چنین سیستم قلبی تحت تاثیر سیستم‌های مختلف بدن از جمله سیستم تنفسی و هورمونی قرار دارد که تعاملات پیچیده‌ی آن‌ها به رفتارهای آشوب‌گونه منجر می‌شود. به طور کلی این عوامل باعث می‌شود سیگنال ECG به عنوان یک سیستم بیولوژیکی پیچیده، رفتار غیرخطی و آشوب‌گونه داشته باشد [۱۸، ۱۹].

در این مقاله ویژگی‌های آنتروپی شانون^۱، آنتروپی تقریبی^۲، آنتروپی نرمال شده^۳، آنتروپی جایگشت^۴، آنتروپی تخمین ریسک بی‌طرفانه‌ی استین^۵ (Sure)، آنتروپی انرژی Log^۶، آنتروپی نمونه^۷، آنتروپی فازی^۸، الگوریتم‌های شاخص ابعاد

۲-۴- استخراج ویژگی

پس از پیش‌پردازش، ویژگی‌های مختلفی از هر سیگنال تجزیه شده استخراج گردیده است. به دلیل ماهیت غیرخطی سیگنال ECG، به نظر می‌رسد که استفاده از ویژگی‌های غیرخطی یک رویکرد مناسب برای تشخیص SCD باشد. سیگنال ECG به دلیل ویژگی‌های ذاتی قلب و سیستم عصبی، دارای دینامیک غیرخطی و آشوب‌گونه است. تعاملات پیچیده‌ی بین سلول‌های قلبی، تاثیر سیستم عصبی خودمختار، فرایندهای الکتروفیزیولوژیکی مانند انتشار امواج الکتریکی و تغییرات یون‌ها، و مکانیسم‌های بازخوردی قلب، همه باعث ایجاد

^۱ Stein's Unbiased Risk Estimate

^۲ Log Energy Entropy

^۳ Sample Entropy

^۴ Fuzzy Entropy

^۱ Shannon Entropy

^۲ Approximate Entropy

^۳ Normalized Entropy

^۴ Permutation Entropy



یک متغیر تصادفی گسسته‌ی X با n مقدار ممکن، حداکثر آنتروپی $H_{\max}(X)$ زمانی حاصل می‌شود که احتمالات $P(X)$ برای تمام مقادیر ممکن x به طور یک‌نواخت توزیع شود، به این معنی که هر نتیجه احتمال وقوع یکسانی دارد. در این مورد $H_{\max}(X)$ برابر با $\log_2(n)$ بوده که نشان دهنده‌ی حداکثر مقدار عدم قطعیت یا اطلاعات است.

۲-۴-۱-۳- آنتروپی تقریبی

آنتروپی تقریبی در سال ۱۹۹۱ توسط پینکوس معرفی شده [۲۲] و به طور گسترده در زمینه‌هایی مانند پردازش سیگنال زیست‌پزشکی و امور مالی مورد استفاده قرار گرفته است. الگوریتم آنتروپی تقریبی به شرح زیر می‌باشد [۲۳].

مرحله ۱: سری زمانی از داده‌ها به شکل زیر را در نظر بگیرید.

$$X = \{u(1), u(2), \dots, u(N)\} \quad (۷)$$

سری زمانی داده‌ها، N مقدار داده‌ی خام از اندازه‌گیری‌هایی هستند که در زمان مساوی فاصله دارند.

مرحله ۲:

(الف) فرض کنید $m \in \mathbb{Z}^+$ یک عدد صحیح مثبت با $m \leq N$ باشد که m طول یک داده (در اصل یک پنجره) را نشان می‌دهد.

(ب) فرض کنید $r \in \mathbb{R}^+$ یک عدد واقعی مثبت باشد که r تعداد سطح فیلتر را مشخص می‌کند.

(ج) فرض کنید $n = N - m + 1$ باشد.

مرحله ۳: برای هر i که $1 \leq i \leq n$ ، رابطه‌ی زیر برقرار است.

$$X(i) = [u(i), u(i+1), \dots, u(i+m-1)] \quad (۵)$$

در واقع $X(i)$ یک بردار m بعدی و شامل اجرای داده‌هایی است که با $u(i)$ شروع می‌شوند. فاصله‌ی بین دو بردار $X(i)$ و $X(j)$ به عنوان حداکثر فاصله‌ی بین اجزای آن‌ها تعریف می‌شود.

$$d[X(i), X(j)] = \max_k (|X(i)_k - X(j)_k|) = \max_k (|u(i+k-1) - u(j+k-1)|) \quad (۹)$$

for $1 \leq k \leq m$

مرحله ۴: تعداد C_i^m به صورت رابطه‌ی (۱۰) تعریف می‌شود.

$$C_i^m(r) = \frac{\text{number of } j \text{ such that } d[X(i), X(j)] \leq r}{n} \quad (۱۰)$$

جعبه^۱ (BDI) و شاخص کانتز^۲ (KI) و ابعاد هیگوجی (HDI) و همبستگی (CD) از سیگنال تجزیه شده استخراج شده است.

۲-۴-۱-۲- آنتروپی

در سیستم‌های غیرخطی، آنتروپی میزان تصادفی بودن، عدم قطعیت یا پیش‌بینی ناپذیری رفتار سیستم را نشان می‌دهد. این کمیت یک اندازه‌گیری از پیچیدگی سیستم و میزان عدم قطعیت یا پیش‌بینی ناپذیری حالت‌های آینده است. آنتروپی نقش اساسی در درک دینامیک، ثبات و محتوای اطلاعاتی سیستم‌های غیرخطی دارد که آن را به یک مفهوم ارزشمند در زمینه‌های فیزیک، ریاضیات، مهندسی و تحلیل سیستم‌های پیچیده تبدیل کرده است [۷]. هم‌چنین آنتروپی کم‌تر به معنی قابل پیش‌بینی بودن سیستم است [۲۰]. آنتروپی‌های مختلفی جهت تشخیص اختلالات در سیگنال‌های بیولوژیکی مورد استفاده قرار گرفته است که هر کدام مزایا و معایب خاص خود را دارند. از آن‌جا که داده‌های مرتبط با SCD معمولاً طی یک زمان طولانی ثبت می‌شود، استفاده از ویژگی‌های غیرخطی موثر که به زمان محاسباتی کوتاه‌تری نیاز دارند، از اولویت برخوردار است. در این مقاله آنتروپی‌های مختلفی از قبیل آنتروپی شانون، آنتروپی تقریبی، آنتروپی نرمال شده، آنتروپی جایگشت، آنتروپی فازی و آنتروپی نمونه به عنوان ویژگی‌های غیرخطی از سیگنال ECG تجزیه شده استخراج گردیده است.

۲-۴-۱-۱- آنتروپی شانون

آنتروپی شانون یک متغیر تصادفی گسسته‌ی X با تابع جرم احتمال $P(X)$ با استفاده از رابطه‌ی (۵) محاسبه می‌شود [۲۱].

$$H(X) = - \sum P(X) * \log_2(P(x)) \quad (۵)$$

۲-۴-۱-۲- آنتروپی نرمال شده

آنتروپی نرمال شده که به عنوان آنتروپی نسبی یا واگرایی اطلاعاتی نیز شناخته می‌شود، معیاری است که آنتروپی یک توزیع احتمال معین را با حداکثر آنتروپی ممکن برای آن توزیع مقایسه می‌کند. آنتروپی نرمال شده با استفاده از رابطه‌ی (۶) محاسبه می‌شود [۲۱].

$$H_{\text{norm}}(X) = \frac{H(X)}{H_{\max}(X)} \quad (۶)$$

در این رابطه $H(X)$ آنتروپی شانون از توزیع X و $H_{\max}(X)$ حداکثر آنتروپی است که توزیع X می‌تواند داشته باشد. در مورد

^۱ Katz Index

^۲ Box Dimension Index

هر بردار جاسازی شده از رابطه‌ی (۱۳) یا (۱۴) با جایگشت π از اعداد صحیح D ($0, 1, \dots, D-1$) جایگزین شده که با الگوی ترتیب مقادیر تشکیل دهنده‌ی بردار تعریف می‌شود. برای هر بردار جاسازی شده‌ی $V = (x_0, x_1, \dots, x_{D-1})$ ، جایگشت که π نام آن است به صورت رابطه‌ی (۱۶) محاسبه می‌شود. تمام اجزای V به صورت نزولی مطابق رابطه‌ی (۱۶) یا به صورت صعودی مطابق رابطه‌ی (۱۷) می‌باشد.

$$V = (x_0, x_1, \dots, x_{D-1}) \\ \rightarrow V_\pi = (x_{r_0}, x_{r_1}, \dots, x_{r_{D-1}}), x_{r_0} > x_{r_1} > \dots > x_{r_{D-1}} \quad (16)$$

$$V = (x_0, x_1, \dots, x_{D-1}) \\ \rightarrow V_\pi = (x_{r_0}, x_{r_1}, \dots, x_{r_{D-1}}), x_{r_0} < x_{r_1} < \dots < x_{r_{D-1}} \quad (17)$$

جایگشت π که مربوط به V است به عنوان ردیف زیرمجموعه‌های بردار V_π بازآرایی شده از هر یک از روابط (۱۶) یا (۱۷) به دست می‌آید.

$$\pi \equiv \pi(V) = (r_0, r_1, \dots, r_{D-1}) \quad (18)$$

از مجموعه‌ی بردارهای جاسازی شده‌ی V ، با جایگزین کردن هر بردار در رابطه‌ی (۱۴) با جایگشت مربوطه، یک مجموعه‌ی جدید (Π) از الگوهای ترتیبی محاسبه می‌شود.

$$\Pi = \{\pi_0, \pi_1, \dots, \pi_{N-D}\} \quad (19)$$

اکنون احتمال تجربی هر جایگشت $P(\pi_i)$ را می‌توان با تقسیم تعداد وقوع π_i در Π بر تعداد کل عناصر در Π به دست آورد. آنتروپی جایگشت V ، آنتروپی شانون توزیع احتمال $P(\pi_i)$ است.

$$H(V) \equiv H(\Pi) = - \sum_{i=0}^{k-1} p(\pi_i) \log(P(\pi_i)) \quad (20)$$

در این رابطه K تعداد جایگشت‌های مختلف در Π است.

۲-۴-۱-۵- آنتروپی نمونه

آنتروپی نمونه نوعی از آنتروپی تقریبی ($ApEn$) است که برخی از محدودیت‌های آن را برطرف می‌کند. برای یک بعد تعبیه شده‌ی m ، تلورانس r و تعداد نقاط داده‌ی N ، آنتروپی نمونه لگاریتم طبیعی منفی این احتمال است که اگر دو مجموعه از نقاط داده هم‌زمان به طول m فاصله‌ی کم‌تر از r داشته باشند، دو مجموعه از نقاط داده هم‌زمان با طول $m+1$ نیز فاصله‌ی کم‌تر از r دارند. آنتروپی نمونه را به صورت $Sample(m, r, N)$ نشان می‌دهند. یک مجموعه‌ی داده‌ی سری زمانی به طول

رابطه‌ی فوق برای هر i به صورت $1 \leq i \leq n$ برقرار است. توجه داشته باشید که از زمانی که تمام مقادیر بین 1 و n را می‌گیرد، تطابق، زمانی شمارش می‌شود که $i=n$ باشد.

مرحله‌ی ۵: رابطه‌ی (۱۱) به صورت زیر تعریف می‌شود.

$$\phi^m(r) = \frac{1}{n} \sum_{i=1}^n \log(C_i^m(r)) \quad (11)$$

در این رابطه \log همان لگاریتم طبیعی و مقدار n ، m و r ثابت است. همان‌طور که در مرحله‌ی ۲ تنظیم شده است.

مرحله‌ی ۶: نهایتاً آنتروپی تقریبی به صورت زیر تعریف می‌شود.

$$ApEn(m, r, N)(u) = \phi^m(r) - \phi^{m+1}(r) \quad (12)$$

۲-۴-۱-۴- آنتروپی جایگشت

برای محاسبه‌ی آنتروپی جایگشت، یک دنباله‌ی محدود از اندازه‌گیری‌ها را در نظر بگیرید [۲۴].

$$X = (x_0, x_1, \dots, x_{N-1}), x_i \in \mathbb{R}^1 \\ i = 0, 1, 2, \dots, N-1. \quad (13)$$

با انتخاب بعد تعبیه‌سازی $D < N$ ، داده‌های رابطه‌ی (۱۳) را می‌توان با انتخاب D سطر متوالی از X در یک فضای D بعدی جاسازی کرد. در نتیجه مجموعه‌ای از بردارهای تعبیه شده‌ی D بعدی به صورت رابطه‌ی (۱۴) به دست می‌آید.

$$V = \{V_0, V_1, \dots, V_{N-D}\}, V_i \in \mathbb{R}^D \\ i = 0, 1, 2, \dots, N-D. \quad (14)$$

در این رابطه هر بردار به صورت رابطه‌ی زیر می‌باشد.

$$V_0 = (x_0, x_1, x_2, \dots, x_{D-1}), \dots \\ V_i = (x_i, x_{i+1}, x_{i+2}, \dots, x_{i+D-1}), \dots \\ V_{N-D} = (x_{N-D}, x_{N+1-D}, \dots, x_{N-1}) \quad (15)$$

یک پارامتر اضافی از روش تعبیه در تعریف بالا، تاخیر ($\tau=1, 2, \dots$) می‌باشد. با $\tau \neq 1$ در رابطه‌ی (۱۶) به جای V_i ، رابطه‌ی V_i به صورت زیر می‌باشد.

$$V_i = (x_i, x_{i+\tau}, x_{i+2\tau}, \dots, x_{i+(D-1)\tau})$$

داده‌های نمایش داده شده در رابطه‌ی (۱۴) یا (۱۵) حتی آن‌هایی که در رابطه‌ی (۱۳) نشان داده شده، اضافی هستند، زیرا برای $D \ll N$ بیش‌تر مقادیر داده از رابطه‌ی (۱۳) در رابطه‌ی (۱۵)، D بار نمایش داده می‌شوند. در تکنیک آنتروپی جایگشت،



بعد معیاری است که نشان می‌دهد چگونه ساختار جزئی یک شی با تغییر مقیاس مشاهده یا اندازه‌گیری تغییر می‌کند. بعد فراکتال با استفاده از تکنیک‌های مختلف ریاضی مانند شمارش جعبه یا بعد همبستگی محاسبه می‌شود. بعد فراکتال محدود به اشیای فیزیکی نیست. هم‌چنین می‌توان آن را برای مفاهیم انتزاعی یا مجموعه‌ی داده‌ها مانند سری‌های زمانی یا تصاویر نیز اعمال کرد. در این مقاله روش‌های شاخص ابعاد جعبه (BDI)، شاخص ابعاد هیگوجی (HDI) و شاخص کاتز (KI) و ابعاد همبستگی (CD) مورد استفاده قرار گرفته است.

۲-۴-۲-۱- شاخص ابعاد جعبه

شاخص ابعاد جعبه (BDI) یک مفهوم ریاضی است که در هندسه‌ی فراکتال برای تعیین کمیت پیچیدگی یا بی‌نظمی یک شکل یا الگوی هندسی استفاده شده و به عنوان بعد شمارش جعبه نیز شناخته می‌شود. شاخص BDI مقدار فضایی که یک شکل هندسی در مقیاس‌های مختلف اشغال کرده را اندازه‌گیری می‌نماید. این شاخص نشان می‌دهد که با بزرگ‌نمایی یا کوچک‌نمایی، شکل چقدر فضا را پر می‌کند. شاخص ابعاد جعبه با استفاده از رابطه‌ی (۲۴) محاسبه می‌شود [۹].

$$BDI_n = - \frac{\ln \left(\frac{\sum_{k=1}^{k-1} |X_n(k+1) - X_n(k)|}{\Delta t} \right)}{\ln(\Delta t)} \quad (24)$$

در این رابطه Δt بازه‌ی زمانی نمونه‌برداری و k تعداد نمونه‌های IMF است [۹].

۲-۴-۲-۲- شاخص ابعاد هیگوجی

بعد فراکتال هیگوجی بی‌نظمی یک سری زمانی را با تجزیه و تحلیل نوسانات در مقیاس‌ها یا وضوح‌های مختلف اندازه‌گیری می‌کند. رویکرد هیگوجی نیازمند محاسبه در چند مرحله است. مرحله‌ی ۱: X را به چندین توالی زمان گسسته S_p^q تجزیه کنید.

$$S_p^q = \{X(q), X(q+p), X(q+2p), \dots, X\left(q + \left\lfloor \frac{k-q}{p} \right\rfloor p\right)\} \quad (25)$$

در این رابطه q می‌تواند مقادیر $1, 2, 3, n$ را بگیرد و p و q مقادیر صحیحی هستند که به ترتیب مقدار اولیه‌ی X و تعداد نمونه‌های حذف شده را تعیین می‌کنند.

مرحله‌ی ۲: طول دنباله‌های تولید شده‌ی S_p^q را با استفاده از رابطه‌ی (۲۶) محاسبه کنید.

$N = \{x_1, x_2, \dots, x_n\}$ با بازه‌ی زمانی ثابت τ را در نظر بگیرید. یک بردار الگو به طول m تعریف می‌شود به طوری که $X_m(i) = \{x_i, x_{i+1}, \dots, x_{i+m-1}\}$ و تابع فاصله‌ی $d[X_m(i), X_m(j)]$ فاصله‌ی چیبیشف است. آنتروپی نمونه به فرم زیر می‌باشد [۲۵].

$$samplerEn = - \ln \frac{A}{B} \quad (21)$$

A تعداد جفت بردار الگو بوده که رابطه‌ی زیر برقرار باشد.

$$d[X_{m+1}(i), X_{m+1}(j)] < r$$

B تعداد جفت بردار الگو بوده که رابطه‌ی زیر برقرار باشد.

$$d[X_m(i), X_m(j)] < r$$

با توجه به این روابط مشخص می‌شود که A همیشه مقداری کوچک‌تر یا مساوی با B دارد. بنابراین $SampEn(m, r, \tau)$ همیشه صفر یا یک مقدار مثبت است. مقدار کوچک‌تر $SampEn$ بیان‌گر شباهت بیش‌تر در مجموعه‌ی داده‌ها یا نویز کم‌تر است.

۲-۴-۱-۶- آنتروپی فازی

آنتروپی فازی بر مبنای نظریه‌ی فازی در ریاضی معرفی شده و یک شاخص غیرخطی است. از خصوصیات آنتروپی فازی ضد نوفه بودن و محدود نشدن آن در برابر تغییر مقدار شبه‌سنج‌ها است. در آنتروپی فازی مفهوم درجه‌ی عضویت با یکی از توابع نمایی زیر به عنوان تابع فازی، برای اندازه‌گیری فازی شباهت دو بردار بر اساس الگوی آن‌ها اجرا می‌شود.

$$\exp \left(\frac{(-d_{ij}^m)^n}{r} \right) \quad (22)$$

مانند دو روش اندازه‌گیر مشابه (آنتروپی تقریبی و آنتروپی نمونه)، آنتروپی فازی لگاریتم طبیعی از احتمال شرطی است که میزان شباهت m نمونه با $m+1$ نمونه‌ی بعدی را نشان می‌دهد. با وارد کردن مفهوم فازی می‌توان میزان شباهت دو بردار را توسط آنتروپی فازی تعریف کرد. در نهایت اندازه‌گیر آنتروپی فازی به صورت اختلاف بین لگاریتم طبیعی توابع Φ^m و Φ^{m+1} مطابق رابطه‌ی (۲۳) محاسبه می‌شود [۲۶].

$$FuzzyEn(m, n, r) = \lim_{N \rightarrow \infty} [\ln(\Phi^m(n, r)) - \ln(\Phi^{m+1}(n, r))] \quad (23)$$

۲-۴-۲- ابعاد فراکتال

بعد فراکتال یک پارامتر ریاضی است که پیچیدگی یا خود شباهت یک جسم یا الگوی هندسی را کمی‌سازی می‌کند. این

برابر لگاریتم فاصله و برازش یک خط رگرسیون، بعد همبستگی را می‌توان به عنوان شیب خط تخمین زد. رابطه‌ی محاسبه‌ی بعد همبستگی به صورت زیر می‌باشد.

$$D = \lim(\log(C(\varepsilon))/\log(\varepsilon)) \quad (۳۱)$$

در این رابطه D بعد همبستگی، ε شعاع یا آستانه‌ی فاصله‌ی استفاده شده و $C(\varepsilon)$ مجموع همبستگی بوده که بیان‌گر تعداد جفت نقاط در فاصله‌ی ε است. در عمل، بعد همبستگی با رسم $\log(C(\varepsilon))$ در مقابل $\log(\varepsilon)$ برای مقادیر مختلف ε تخمین زده می‌شود. سپس یک رگرسیون خطی روی نمودار انجام شده و شیب خط تقریبی از بعد همبستگی به دست می‌آید [۲۸].

۲-۵- انتخاب ویژگی

انتخاب ویژگی فرایندی است که در آن تعداد ویژگی‌های مناسبی که از تعداد ویژگی‌های اصلی کم‌تر بوده برای طبقه‌بندی استفاده می‌شود. در واقع این فرایند باعث تسریع عمل‌کرد طبقه‌بندی می‌شود. در این مقاله از آزمون t -test و ANOVA برای رتبه‌بندی ویژگی‌های غیرخطی استخراج شده استفاده گردیده است. آزمون t یک آزمون آماری است که از آن برای تعیین تفاوت معنی‌داری بین میانگین دو گروه استفاده می‌شود. در انتخاب ویژگی می‌توان از آزمون t برای مقایسه‌ی میانگین‌های یک ویژگی خاص بین دو کلاس یا گروه استفاده کرد. اگر آزمون t تفاوت معنی‌داری را نشان دهد، مشخص می‌شود که این ویژگی ممکن است برای تمایز بین گروه‌ها مرتبط باشد و می‌تواند برای انتخاب ویژگی در نظر گرفته شود [۳۰]. رابطه‌ی آزمون t نمونه‌های مستقل به صورت زیر است.

$$A = (x_1 - x_2) / \sqrt{\left(\frac{S_1^2}{n_1}\right) + \left(\frac{S_2^2}{n_2}\right)} \quad (۳۲)$$

در این رابطه x_1 و x_2 میانگین یک ویژگی خاص در دو گروه مورد مقایسه، s_1 و s_2 انحراف معیار دو گروه و n_1 و n_2 حجم نمونه‌ی دو گروه است. مقدار t به دست آمده از این رابطه را می‌توان با مقدار t قطعی از توزیع t با درجات آزادی تعیین شده توسط اندازه‌ی نمونه و با فرض سطح معنی‌داری معینی (مثلاً ۰/۰۵) مقایسه کرد. اگر مقدار t محاسبه شده از مقدار t قطعی بیش‌تر شود، بیان‌گر تفاوت معنی‌دار بین میانگین دو گروه است که نشان می‌دهد این ویژگی در پیش‌بینی متغیر هدف ارتباط دارد. تفاوت ANOVA و t -test این است که در ANOVA علاوه بر تفاوت میانگین، واریانس‌های ویژگی در گروه‌های مختلف نیز در تعیین میزان تمایز آن ویژگی تاثیر می‌گذارد. بعد از فرایند

$$L_q(p) = \left\{ \left(\sum_{i=1}^{\lfloor \frac{k-q}{p} \rfloor} |S_p^i - S_p^{i-1}| \right) \left[\frac{k-1}{\lfloor \frac{k-q}{p} \rfloor} \right]_p \right\} \quad (۲۶)$$

مرحله‌ی ۳: مجموع تمام دنباله‌های ایجاد شده را با استفاده از رابطه‌ی (۲۷) محاسبه کنید.

$$L(p) = \sum_{q=1}^p L_q(p) \quad (۲۷)$$

مرحله‌ی ۴: شیب خطی را که با صفحه‌ی رسم شده‌ی زیر مطابقت دارد محاسبه کنید. شیب به دست آمده همان مقدار HI است [۹].

$$\left(\ln\left(\frac{1}{q}\right), \ln(l(q)) \right)$$

۲-۴-۲-۳- شاخص کاتز

شاخص کاتز معیاری است که از آن برای تعیین کمیت مرکزیت یا اهمیت گره‌ها در یک شبکه استفاده می‌شود [۲۹]. شاخص کاتز با استفاده از رابطه‌ی (۲۸) محاسبه می‌شود [۹].

$$KI_n = \frac{\log_{10}\left(\frac{L_n}{a}\right)}{\log_{10}\left(\frac{d}{a}\right)} \quad (۲۹)$$

در این رابطه L_n و a با استفاده از روابط (۲۹) و (۳۰) به دست می‌آید که در آن k طول IMF است.

$$L_n = \sum_{k=2}^k \text{distance}(IMF_n(k) - IMF_n(k-1)) \quad (۲۹)$$

$$a = \frac{L_n}{k-1} \quad (۳۰)$$

۲-۴-۲-۴- ابعاد همبستگی

بعد همبستگی معیاری است که در زمینه‌ی هندسه‌ی فراکتال به کار می‌رود تا پیچیدگی و خودشبهی را در یک مجموعه‌ی داده یا سری زمانی به تصویر بکشد. بعد همبستگی میزان وابستگی بین نقاط یک فضای فاز یا جذب کننده را کمی می‌کند. برای محاسبه‌ی بعد همبستگی معمولاً از روشی به نام الگوریتم گراسبرگر-پروکاپیا استفاده می‌شود [۲۷]. در این الگوریتم، نقاط داده در یک فضای فاز با ابعاد بالا نگاشت می‌شود. سپس برای فواصل یا شعاع‌های مختلف، تعداد جفت نقاط در آن فاصله شمارش می‌شود. با رسم لگاریتم تعداد جفت‌ها در



۲-۶-۲- طبقه‌بند KNN

طبقه‌بند KNN یکی از ساده‌ترین الگوریتم‌های یادگیری ماشین با هزینه‌ی محاسباتی کم است [۵]. در بازشناخت الگو KNN یک روش غیرپارامتری است که برای طبقه‌بندی آماری و رگرسیون استفاده می‌شود. در این طبقه‌بند با توجه به مقدار مشخص شده برای k ، فاصله‌ی نقطه‌ای که باید برچسب آن مشخص شود با نزدیک‌ترین نقاط محاسبه شده و با توجه به تعداد رای حداکثری این نقاط همسایه، در رابطه با برچسب نقطه‌ی مورد نظر تصمیم‌گیری می‌شود. برای محاسبه‌ی این فاصله می‌توان از روش‌های مختلفی استفاده کرد که یکی از مطرح‌ترین این روش‌ها فاصله‌ی اقلیدسی است. در حالت رگرسیون نیز میانگین مقادیر به دست آمده از k خروجی آن است. از آن‌جا که محاسبات این الگوریتم بر اساس فاصله است نرمال‌سازی داده‌ها می‌تواند به بهبود عمل کرد آن کمک کند.

۳- بحث و نتایج

در این پژوهش با استفاده از تجزیه‌ی حالت تجربی، هر سیگنال ECG به ۶ مولفه‌ی ذاتی تجزیه شده و از هر IMF، ۱۰ ویژگی استخراج شده است. در مجموع از هر بخش ۱ دقیقه‌ای ۱۲۰ ویژگی استخراج شده است. تعداد ویژگی‌های انتخاب شده برای هر دقیقه در این مقاله متغیر و بین ۴ تا ۲۰ ویژگی بوده که برای هر دقیقه بیش‌ترین صحت به دست آمده گزارش شده است. در این مطالعه از روش اعتبارسنجی متقابل K لایه‌ی^۲ استفاده شده است. در این روش مجموعه‌ی داده معمولاً به K زیرمجموعه با اندازه‌ی تقریباً مساوی تقسیم می‌شود. یک زیرمجموعه برای اعتبارسنجی در نظر گرفته شده، در حالی که از سایر زیرمجموعه‌ها برای آموزش مدل استفاده می‌شود. این فرایند K بار تکرار شده و هر زیرمجموعه یک بار برای اعتبارسنجی استفاده می‌گردد. سپس عمل کرد مدل بر اساس میانگین عمل کرد در تمام زیرمجموعه‌ها ارزیابی می‌شود. در این پژوهش $K=10$ در نظر گرفته شده است. از آن‌جا که تعداد نمونه‌های بیمار و سالم در پایگاه داده‌ی مورد استفاده برابر است مجموعه‌ی داده‌ی آموزش و تست متوازن می‌باشد. در این مقاله علاوه بر میانگین کل صحت‌ها، انحراف معیار آن‌ها نیز گزارش شده است. صحت نشان دهنده‌ی میزان نزدیک بودن مقدار پیش‌بینی به مقدار واقعی است و به صورت زیر محاسبه می‌شود.

$$accuracy = \frac{TP + FN}{TP + FN + TN + FP} \times 100 \quad (۳۵)$$

^۲ K-Fold Cross Validation

انتخاب ویژگی برای طبقه‌بندی افراد در معرض خطر SCD و افراد نرمال از دو طبقه‌بند SVM و KNN استفاده شده است.

۲-۶-۲- طبقه‌بندی


در این مقاله از طبقه‌بند ماشین بردار پشتیبان و k -نزدیک‌ترین همسایگی استفاده شده است.

۲-۶-۱- طبقه‌بند SVM

طبقه‌بند SVM با توجه به داده‌های برچسب‌دار آموزشی، یک ابر فضای بهینه را ارائه کرده تا داده‌های جدید را به دسته‌های مختلف طبقه‌بندی کند. این روش از جمله روش‌های جدیدی بوده که در سال‌های اخیر عمل‌کرد خوبی نسبت به روش‌های قدیمی برای طبقه‌بندی داشته است. اساس طبقه‌بندی SVM طبقه‌بندی خطی داده‌ها است. مطابق شکل (۴) ماشین بردار پشتیبانی در واقع یک طبقه‌بند دودویی است که دو کلاس را با استفاده از یک مرز خطی با بیشینه‌سازی حاشیه از هم جدا می‌کند که به صورت رابطه‌ی (۳۳) بیان می‌شود [۳۱].

$$y(X) = W^T \varphi(X) + b \quad (۳۳)$$

در این رابطه W بردار وزن، b پارامتر بایاس و φ تابع هسته است. عمل کرد SVM به نوع تابع هسته‌ی مورد استفاده بستگی دارد. برای جداسازی داده‌های غیرخطی، استفاده از توابع هسته‌ی غیرخطی باعث بهبود عمل کرد SVM می‌شود. یکی از انواع متداول توابع غیرخطی، توابع پایه‌ی شعاعی (RBF) است.



شکل (۴) - طبقه‌بندی با بیشینه‌سازی حاشیه در SVM

۲-۶-۱-۱- تابع کرنل پایه‌ی شعاعی

کرنل تابع پایه‌ی شعاعی^۱ (RBF) برای تبدیل SVM به یک طبقه‌بندی کننده‌ی غیرخطی استفاده می‌شود. تابع RBF میزان شباهت یا نزدیک بودن دو بردار X_i و X_j به یکدیگر را به صورت زیر محاسبه می‌کند.

$$k(X_i, X_j) = \exp(-\sigma \|X_i - X_j\|^2) \quad (۳۴)$$

^۱ Radial Basis Function

ویژگی‌های به دست آمده مشخص شده که ویژگی‌های آنتروپی جایگشت و آنتروپی تقریبی و ابعاد هیگوجی بهترین تمایز را از دیدگاه معیار ارزیابی t-test داشته‌اند.

در جدول‌های (۱) و (۲) نتایج به دست آمده از روش پیشنهادی با بهره‌گیری از انتخاب ویژگی t-test به ازای طبقه‌بندی کننده‌های SVM و KNN گزارش شده است. با بررسی

جدول (۲) - صحت به دست آمده برای ۶۰ دقیقه قبل از SCD

با استفاده از t-test و طبقه‌بند KNN

دقیقه	صحت	دقیقه	صحت	دقیقه	صحت
۱	۹۱	۲۱	۸۸/۲۱	۴۱	۸۹
۲	۹۴/۷۳	۲۲	۹۶/۸۴	۴۲	۹۵
۳	۹۷/۳۱	۲۳	۸۹/۴۷	۴۳	۹۴/۱۰
۴	۹۴/۷۳	۲۴	۸۹/۷۳	۴۴	۹۴/۷۳
۵	۹۱/۷۳	۲۵	۸۹/۴۲	۴۵	۹۱/۳۶
۶	۹۷/۳۶	۲۶	۹۴/۷۳	۴۶	۹۶/۰۵
۷	۹۴/۵۲	۲۷	۹۷/۳۶	۴۷	۹۴
۸	۹۴/۵۲	۲۸	۹۴	۴۸	۹۴
۹	۹۴/۷۳	۲۹	۹۷/۳۱	۴۹	۹۵/۱۵
۱۰	۹۲/۱۰	۳۰	۹۷/۲۱	۵۰	۹۷
۱۱	۹۶/۸۴	۳۱	۹۷	۵۱	۹۳/۶۸
۱۲	۹۲/۱۵	۳۲	۹۹/۵۲	۵۲	۹۴
۱۳	۸۹/۲۶	۳۳	۹۴/۷۳	۵۳	۹۷
۱۴	۹۲/۲۱	۳۴	۹۴/۶۸	۵۴	۹۹/۲۱
۱۵	۹۲/۱۵	۳۵	۹۴/۷۳	۵۵	۱۰۰
۱۶	۸۹/۱۰	۳۶	۹۲/۱۰	۵۶	۹۶/۲۱
۱۷	۹۴/۶۸	۳۷	۹۳/۵۲	۵۷	۹۷
۱۸	۹۴/۱۵	۳۸	۹۷/۴۷	۵۸	۱۰۰
۱۹	۹۷/۳۶	۳۹	۹۲/۰۵	۵۹	۹۶/۴۷
۲۰	۹۱/۷۳	۴۰	۹۲/۴۷	۶۰	۹۴/۷۳

میانگین کل صحت \pm انحراف معیار = $94/42 \pm 2/9124$ %

جدول (۱) - صحت به دست آمده برای ۶۰ دقیقه قبل از SCD

با استفاده از t-test و طبقه‌بند SVM

دقیقه	صحت	دقیقه	صحت	دقیقه	صحت
۱	۸۵/۶۸	۲۱	۸۹/۳۶	۴۱	۹۲/۰۵
۲	۹۴/۶۳	۲۲	۹۲/۱۵	۴۲	۹۲/۰۵
۳	۹۴/۲۶	۲۳	۸۹/۴۷	۴۳	۹۱/۰۵
۴	۹۴/۷۳	۲۴	۹۰	۴۴	۹۴/۷۲
۵	۸۹/۶۸	۲۵	۹۰	۴۵	۸۷
۶	۹۵/۳۱	۲۶	۹۴/۷۳	۴۶	۹۳/۴۲
۷	۹۷/۳۱	۲۷	۹۷/۲۶	۴۷	۹۳/۰۵
۸	۹۲/۶۸	۲۸	۹۲	۴۸	۹۴/۱۰
۹	۹۴/۷۳	۲۹	۹۷	۴۹	۹۴/۷۸
۱۰	۹۲/۲۶	۳۰	۹۷/۱۰	۵۰	۹۵/۱۰
۱۱	۹۴/۷۸	۳۱	۹۷/۱۵	۵۱	۸۸/۱۰
۱۲	۹۰/۴۷	۳۲	۹۷/۴۷	۵۲	۹۴/۶۸
۱۳	۸۸/۱۵	۳۳	۹۴/۷۳	۵۳	۹۶/۳۱
۱۴	۹۵/۸۴	۳۴	۹۵/۲۶	۵۴	۹۷/۰۵
۱۵	۹۵/۲۶	۳۵	۹۴	۵۵	۱۰۰
۱۶	۹۰	۳۶	۹۴/۳۱	۵۶	۹۶
۱۷	۹۴/۴۲	۳۷	۹۵/۰۵	۵۷	۹۷/۰۵
۱۸	۹۴	۳۸	۹۷/۳۶	۵۸	۱۰۰
۱۹	۹۷/۳۶	۳۹	۹۲/۱۰	۵۹	۹۵/۱۵
۲۰	۹۰/۳۱	۴۰	۹۳/۱۰	۶۰	۹۳

میانگین کل صحت \pm انحراف معیار = $93/77 \pm 3/0625$ %

نتیجه گرفت که طبقه‌بند KNN نسبت به طبقه‌بند SVM میانگین کل صحت بهتری را به دست آورده است.

در جدول‌های (۳) و (۴) نتایج روش پیشنهادی با استفاده از انتخاب ویژگی ANOVA به ازای طبقه‌بندهای SVM و KNN گزارش شده است. با بررسی ویژگی‌های به دست آمده مشخص شده که ویژگی‌های آنتروپی جایگشت و ابعاد هیگوجی بهترین تمایز را از دیدگاه معیار ارزیابی ANOVA داشته‌اند. جدول (۳) مربوط به طبقه‌بند SVM و انتخاب ویژگی ANOVA برای ۶۰ دقیقه قبل از SCD است. مشاهده می‌شود که بیش‌ترین صحت به دست آمده مربوط به دقیقه‌ی ۵۸ با دقت ۱۰۰٪ است. کم‌ترین صحت به دست آمده نیز مربوط به دقیقه‌ی ۴۵ با دقت ۸۷/۲۶٪ می‌باشد. میانگین کل صحت به دست آمده برای ۶۰ دقیقه قبل از SCD با استفاده از ANOVA و طبقه‌بند SVM برابر با ۹۳/۵۸٪ است. در جدول (۴) صحت‌های به دست آمده برای ۶۰ دقیقه قبل از SCD با استفاده از ANOVA و طبقه‌بند

جدول (۱) مربوط به استفاده از طبقه‌بند SVM و انتخاب ویژگی t-test برای ۶۰ دقیقه قبل از SCD است. بر اساس این جدول مشاهده می‌شود که بیش‌ترین صحت به دست آمده مربوط به دقیقه‌های ۵۵ و ۵۸ با مقدار ۱۰۰٪ است. کم‌ترین صحت به دست آمده نیز مربوط به دقیقه‌ی ۱ با مقدار ۸۵/۶۸٪ است. میانگین کل صحت به دست آمده برای ۶۰ دقیقه قبل از SCD با استفاده از انتخاب ویژگی t-test و طبقه‌بند SVM برابر با ۹۳/۷۷٪ می‌باشد. در جدول (۲) صحت‌های به دست آمده برای ۶۰ دقیقه قبل از SCD با استفاده از t-test و طبقه‌بندی کننده‌ی KNN (K=3) ارائه شده است. مشاهده می‌شود که بیش‌ترین صحت به دست آمده برای دقیقه‌های ۵۵ و ۵۸ با مقدار ۱۰۰٪ است. کم‌ترین صحت به دست آمده نیز مربوط به دقیقه‌ی ۲۱ با صحت ۸۸/۲۱٪ است. میانگین کل صحت به دست آمده با استفاده از انتخاب ویژگی t-test برای ۶۰ دقیقه قبل از SCD برابر با ۹۴/۴۲٪ می‌باشد. با توجه به جداول (۱) و (۲) می‌توان

قبل از SCD با استفاده از ANOVA و طبقه‌بند KNN برابر با ۹۴/۳۱٪ است. با توجه به جداول (۳) و (۴) می‌توان نتیجه گرفت که روش طبقه‌بندی KNN نسبت به روش طبقه‌بندی SVM میانگین کل صحت بهتری را به دست آورده است.

KNN (K=3) ارائه شده است. بیش‌ترین صحت به دست آمده مربوط به دقیقه‌ی ۵۸ با مقدار ۱۰۰٪ است. کم‌ترین صحت به دست آمده نیز مربوط به دقیقه‌های ۱، ۱۰، ۱۶ و ۲۳ با مقدار ۹۰٪ می‌باشد. میانگین کل صحت به دست آمده برای ۶۰ دقیقه

جدول (۴) - صحت به دست آمده برای ۶۰ دقیقه قبل از SCD

با استفاده از ANOVA و طبقه‌بند KNN

دقیقه	صحت	دقیقه	صحت	دقیقه	صحت
۱	۹۰	۲۱	۹۰/۰۵	۴۱	۹۱/۵۷
۲	۹۴/۷۳	۲۲	۹۲/۶۳	۴۲	۹۴/۵۲
۳	۹۵/۰۵	۲۳	۹۰	۴۳	۹۴/۰۵
۴	۹۴/۳۶	۲۴	۹۰/۳۶	۴۴	۹۴/۷۳
۵	۹۲	۲۵	۹۱/۵۲	۴۵	۹۰/۴۲
۶	۹۵/۲۶	۲۶	۹۴/۵۲	۴۶	۹۵/۴۷
۷	۹۷/۳۶	۲۷	۹۷/۳۶	۴۷	۹۴/۵۲
۸	۹۳/۴۲	۲۸	۹۲/۲۱	۴۸	۹۴/۶۸
۹	۹۴/۳۱	۲۹	۹۶/۶۳	۴۹	۹۲/۱۵
۱۰	۹۰	۳۰	۹۷/۴۲	۵۰	۹۷/۳۱
۱۱	۹۵/۲۶	۳۱	۹۷/۱۵	۵۱	۹۱/۴۲
۱۲	۹۰/۷۳	۳۲	۹۹/۷۸	۵۲	۹۴/۱۰
۱۳	۹۰	۳۳	۹۳/۴۲	۵۳	۹۷/۱۵
۱۴	۹۳/۲۶	۳۴	۹۷/۲۱	۵۴	۹۷/۴۲
۱۵	۹۲	۳۵	۹۲/۵۲	۵۵	۹۹/۸۴
۱۶	۹۰	۳۶	۹۲/۷۸	۵۶	۹۴/۶۳
۱۷	۹۴/۳۱	۳۷	۹۶/۶۳	۵۷	۹۷
۱۸	۹۴/۴۷	۳۸	۹۷/۱۵	۵۸	۱۰۰
۱۹	۹۷/۳۱	۳۹	۹۲/۰۵	۵۹	۹۷/۳۱
۲۰	۹۳/۴۷	۴۰	۹۴/۱۰	۶۰	۹۴/۷۳

میانگین کل صحت \pm انحراف معیار = 94.31 ± 2.70 ٪

جدول (۳) - صحت به دست آمده برای ۶۰ دقیقه قبل از SCD

با استفاده از ANOVA و طبقه‌بند SVM

دقیقه	صحت	دقیقه	صحت	دقیقه	صحت
۱	۹۱/۲۶	۲۱	۸۹/۳۱	۴۱	۹۲/۱۰
۲	۹۴/۶۳	۲۲	۹۲	۴۲	۹۲/۷۸
۳	۹۴/۷۸	۲۳	۸۹/۲۶	۴۳	۹۱/۴۷
۴	۹۴/۷۳	۲۴	۸۸/۲۱	۴۴	۹۴/۴۷
۵	۹۰	۲۵	۹۰/۵۲	۴۵	۸۷/۲۶
۶	۹۵/۲۱	۲۶	۹۴/۷۳	۴۶	۹۳/۴۷
۷	۹۷/۳۱	۲۷	۹۷/۲۶	۴۷	۹۲/۵۷
۸	۹۲/۱۰	۲۸	۹۴/۲۲	۴۸	۹۳/۶۸
۹	۹۴/۵۷	۲۹	۹۴/۳۱	۴۹	۹۴/۷۳
۱۰	۹۲	۳۰	۹۶/۸۳	۵۰	۹۴/۵۲
۱۱	۹۴/۶۸	۳۱	۹۷/۳۶	۵۱	۸۸/۷۳
۱۲	۹۰	۳۲	۹۷/۲۱	۵۲	۹۴/۴۷
۱۳	۸۷/۶۸	۳۳	۹۴/۶۳	۵۳	۹۶/۴۲
۱۴	۹۲/۴۷	۳۴	۹۵/۱۵	۵۴	۹۷/۲۷
۱۵	۹۱/۸۹	۳۵	۹۴/۰۵	۵۵	۹۹/۵۲
۱۶	۹۰/۳۶	۳۶	۹۴/۰۵	۵۶	۹۵/۲۱
۱۷	۹۴/۳۱	۳۷	۹۵/۳۱	۵۷	۹۷
۱۸	۹۲/۳۶	۳۸	۹۷/۳۶	۵۸	۱۰۰
۱۹	۹۷/۳۶	۳۹	۹۲/۱۰	۵۹	۹۵/۲۱
۲۰	۹۰/۱۰	۴۰	۹۲/۲۱	۶۰	۹۳

میانگین کل صحت \pm انحراف معیار = 93.58 ± 2.92 ٪

۵۲ دیده می‌شود. به همین دلیل است که در اکثر مقالات، میانگین صحت‌های به دست آمده در دقایق و بازه‌های زمانی مختلف قبل از SCD گزارش می‌گردد. در مطالعه‌ی [۱۰] کم‌ترین صحت به دست آمده برای دقیقه‌های مختلف به ۸۰٪ نیز رسیده اما کم‌ترین صحت به دست آمده برای ۶۰ دقیقه قبل از SCD با استفاده از رویکرد پیشنهادی ۸۶/۳۶٪ است. در رویکرد پیشنهادی نسبت به مطالعه‌ی [۱۰] برای ۶۰ دقیقه قبل از SCD میانگین کل صحت بیش‌تری به دست آمده است. در جدول (۵) نتایج مقایسه‌ی عمل‌کرد روش پیشنهادی با سایر روش‌های پیشین در زمینه‌ی پیش‌بینی SCD گزارش شده است. مشاهده می‌شود که محققان از طول داده‌های مختلفی برای بررسی سیگنال ECG و وقوع SCD استفاده نموده‌اند. با مقایسه‌ی طول بازه‌های زمانی استفاده شده، مشاهده می‌شود که مطالعه‌ی حاضر جزو معدود مطالعاتی بوده که ۶۰ دقیقه

با مقایسه‌ی نتایج به دست آمده ملاحظه می‌شود که در رویکرد پیشنهادی با انتخاب ویژگی t-test و طبقه‌بند KNN بهترین عمل‌کرد به دست آمده است. شاید این پرسش به ذهن برسد که چرا میزان صحت در دقایق نزدیک به وقوع SCD کم‌تر از دقایق دورتر است. در پاسخ باید گفت که در تئوری با نزدیک شدن به وقوع SCD، احتمال مشاهده‌ی ویژگی‌های مربوط به رخداد SCD بیش‌تر خواهد بود اما به دلیل ماهیت غیرخطی سیگنال ECG ممکن است در دقایق دورتری نیز این چنین ویژگی‌هایی مشاهده شود. در مطالعات پیشین از جمله مقالات [۹، ۱۰] صحت‌های به دست آمده در بعضی از بازه‌های دورتر از دقیقه‌های رخداد SCD نیز افزایش داشته است. به عنوان مثال در مقاله‌ی [۹] صحت به دست آمده در ۱ دقیقه قبل از SCD کم‌تر از ۲۵ و ۲۴ دقیقه قبل از SCD می‌باشد. این موضوع در نتایج مقاله‌ی [۱۰] نیز در مورد دقایق ۲۵، ۳۴، ۵۰، ۵۱ و

حالی که روش پیشنهادی مقاله‌ی حاضر به ازای ۴ دقیقه قبل از SCD می‌تواند به میانگین صحت ۹۴/۴۲٪ برسد. شی و هم‌کارانش [۸] نیز میانگین صحت به دست آمده در ۱۴ دقیقه قبل از SCD را ۹۶٪ گزارش کرده‌اند که این مقدار در روش پیشنهادی ۹۳/۸۰٪ است. هم‌چنین آن‌ها در مقاله‌ی دیگری برای ۱۴ دقیقه قبل از SCD به میانگین صحت ۹۷/۶٪ رسیده‌اند [۱۳]. سنتو و هم‌کارانش [۱۴] برای ۳۰ دقیقه قبل از SCD میانگین صحت ۹۷/۵٪ را گزارش کرده‌اند که در روش پیشنهادی این میزان ۹۳/۵۵٪ است. خزایی و هم‌کارانش [۵] بالاترین صحت به دست آمده در ۶ دقیقه قبل از SCD را ۹۵٪ گزارش کرده‌اند. این میزان برای روش پیشنهادی ۹۴/۴۸٪ است. در حالت کلی روش ارائه شده در این مقاله در مقایسه با روش‌های پیشین نتایج قابل قبولی را به دست آورده است.

قبل از وقوع SCD را بررسی کرده است. وارقاس و هم‌کارانش [۹] با استفاده از طول داده‌ی ۲۵ دقیقه قبل از SCD و تجزیه‌ی سیگنال به روش EMD به میانگین کل صحت ۹۴٪ دست یافته‌اند. رویکرد پیشنهادی مقاله‌ی حاضر برای ۲۵ دقیقه قبل از SCD به میانگین صحت کل ۹۳/۰۴٪ رسیده که در مقایسه با مقاله‌ی [۹] ۰/۹۶٪ کم‌تر است. پیناواگا و هم‌کارانش [۱۰] با استفاده از طول داده‌ی ۶۰ دقیقه قبل از SCD و استخراج ویژگی‌های ابعاد فراکتال به میانگین کل صحت ۹۱/۵۸٪ دست یافته‌اند. رویکرد پیشنهادی مقاله‌ی حاضر با طول داده‌ی ۶۰ دقیقه قبل از SCD نسبت به رویکرد مقاله‌ی [۱۰] نتیجه‌ی بهتری را ارائه داده است. آچاریا و هم‌کارانش [۱۱] با استفاده از طول داده‌ی ۴ دقیقه قبل از SCD و استخراج روش هلی غیرخطی به میانگین کل صحت ۹۲/۱۱٪ دست یافته‌اند، در

جدول (۵) - مقایسه‌ی عمل‌کرد رویکرد پیشنهادی با مطالعات پیشین

مرجع	طول داده	تعداد افراد	میانگین کل صحت
خزایی و هم‌کارانش [۵]	۶ دقیقه قبل از SCD	۲۰ SCD - ۱۸ نرمال	بالاترین صحت با طبقه‌بند DT = ۹۵٪
شی و هم‌کارانش [۸]	۱۴ دقیقه قبل از SCD	۲۰ SCD - ۱۸ نرمال	بالاترین صحت با طبقه‌بند KNN = ۹۶/۱٪
وارقاس و هم‌کارانش [۹]	۲۵ دقیقه قبل از SCD	۲۰ SCD - ۱۸ نرمال	میانگین کل صحت با طبقه‌بند MLP = ۹۴٪
آچاریا و هم‌کارانش [۱۱]	۴ دقیقه قبل از SCD	۲۰ SCD - ۱۸ نرمال	میانگین کل صحت با طبقه‌بند SVM = ۹۲/۱۱٪
پیناواگا و هم‌کارانش [۱۰]	۶۰ دقیقه قبل از SCD	۲۰ SCD - ۱۸ نرمال	میانگین کل صحت با طبقه‌بند FLS = ۹۱/۵۸٪
شی و هم‌کارانش [۱۳]	۱۴ دقیقه قبل از SCD	۲۰ SCD - ۱۸ نرمال	بالاترین صحت در دقیقه‌ی ۱۴ با طبقه‌بند KNN = ۹۷/۶٪
سنتو و هم‌کارانش [۱۴]	۳۰ دقیقه قبل از SCD	۲۰ SCD - ۱۸ نرمال	صحت در دقیقه‌ی ۳۰ با طبقه‌بند CNN = ۹۷/۵٪
رویکرد پیشنهادی	۶۰ دقیقه قبل از SCD	۲۰ SCD - ۱۸ نرمال	میانگین کل صحت با طبقه‌بند KNN و انتخاب ویژگی t-test = ۹۴/۴۲٪

۵- مراجع

- [1] S. M. Al-Khatib et al., "Preventing tomorrow's sudden cardiac death today: part I: current data on risk stratification for sudden cardiac death," *American heart journal*, vol. 153, no. 6, pp. 941-950, 2007.
- [2] D. P. Zipes and H. J. Wellens, "Sudden cardiac death," *Circulation*, vol. 98, no. 21, pp. 2334-2351, 1998.
- [3] T.-W. Shen, H.-P. Shen, C.-H. Lin, and Y.-L. Ou, "Detection and prediction of sudden cardiac death (SCD) for personal healthcare," in 2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 2007: IEEE, pp. 2575-2578.
- [4] E. Ebrahimzadeh et al., "An optimal strategy for prediction of sudden cardiac death through a pioneering feature-selection approach from HRV signal," *Computer methods and programs in biomedicine*, vol. 169, pp. 19-36, 2019.
- [5] M. Khazaei, K. Raeisi, A. Goshvarpour, and M. Ahmadzadeh, "Early detection of sudden cardiac death using nonlinear analysis of heart rate

۴- نتیجه‌گیری

در این مطالعه یک روش به منظور پیش‌بینی مرگ ناگهانی قلبی (SCD) بر اساس تجزیه و تحلیل زمان-فرکانس سیگنال‌های ECG ارائه شده است. در این روش پیشنهادی با استخراج نمودن ویژگی‌های غیرخطی از خروجی تجزیه‌ی حالت تجربی روی سیگنال‌های ECG و استفاده از دو روش انتخاب ویژگی آماری به پیش‌بینی SCD پرداخته شده است. برای ارزیابی روش پیشنهادی از دو پایگاه داده‌ی آنلاین فیزیونت استفاده شده است. نتایج ارزیابی‌ها نشان داده که روش پیشنهادی این پژوهش در مقایسه با روش‌های پیشین نتایج قابل قبولی را به دست آورده است. این یافته‌ها عمل‌کرد امیدوارکننده‌ی روش پیشنهادی در پیش‌بینی SCD را نشان می‌دهد. با توجه به نتایج این مطالعه می‌توان گفت که روش پیشنهادی می‌تواند در پیش‌بینی به موقع SCD موثر باشد و از این طریق به کاهش مرگ‌ومیر ناشی از این عارضه کمک کند.

- [18] M. R. Guevara, L. Glass, and A. Shrier, "Phase locking, period-doubling bifurcations, and irregular dynamics in periodically stimulated cardiac cells," *Science*, vol. 214, no. 4527, pp. 1350-1353, 1981.
- [19] J. P. Sturmburg and B. J. West, "Fractals in physiology and medicine," in *Handbook of systems and complexity in health*: Springer, 2012, pp. 171-192.
- [20] D. Parbat and M. Chakraborty, "A novel methodology to study the cognitive load induced EEG complexity changes: Chaos, fractal and entropy based approach," *Biomedical Signal Processing and Control*, vol. 64, p. 102277, 2021.
- [21] U. R. Acharya et al., "Entropies for automated detection of coronary artery disease using ECG signals: A review," *Biocybernetics and Biomedical Engineering*, vol. 38, no. 2, pp. 373-384, 2018.
- [22] S. Pincus, "Approximate entropy (ApEn) as a complexity measure," *Chaos: An Interdisciplinary Journal of Nonlinear Science*, vol. 5, no. 1, pp. 110-117, 1995.
- [23] S. A. Hosseini and M. B. Naghibi-Sistani, "Emotion recognition method using entropy analysis of EEG signals," *International Journal of Image, Graphics and Signal Processing*, vol. 3, no. 5, p. 30, 2011.
- [24] A. K. Vidybida, "Calculating permutation entropy without permutations," *Complexity*, vol. 2020, pp. 1-9, 2020.
- [25] S. J. J. Jui, R. C. Deo, P. D. Barua, A. Devi, J. Soar, and U. R. Acharya, "Application of entropy for automated detection of neurological disorders with electroencephalogram signals: A review of the last decade (2012-2022)," *IEEE Access*, 2023.
- [26] S. Al-Sharhan, F. Karray, W. Gueaieb, and O. Basir, "Fuzzy entropy: a brief survey," in *10th IEEE international conference on fuzzy systems*. (Cat. No. 01CH37297), 2001, vol. 3: IEEE, pp. 1135-1139.
- [27] P. Grassberger and I. Procaccia, "Measuring the strangeness of strange attractors," *Physica D: nonlinear phenomena*, vol. 9, no. 1-2, pp. 189-208, 1983.
- [28] J. C. Sprott and G. Rowlands, "Improved correlation dimension calculation," *International Journal of Bifurcation and Chaos*, vol. 11, no. 07, pp. 1865-1880, 2001.
- [29] L. Katz, "A new status index derived from sociometric analysis," *Psychometrika*, vol. 18, no. 1, pp. 39-43, 1953.
- [30] T. L. Weissgerber, O. Garcia-Valencia, V. D. Garovic, N. M. Milic, and S. J. Winham, "Why we need to report more than 'Data were Analyzed by t-tests or ANOVA'," *Elife*, vol. 7, p. e36163, 2018.
- [31] C. M. Bishop and N. M. Nasrabadi, *Pattern recognition and machine learning* (no. 4). Springer, 2006.
- variability," *Biocybernetics and Biomedical Engineering*, vol. 38, no. 4, pp. 931-940, 2018.
- [6] P. Markwerth, T. Bajanowski, I. Tzimas, and R. Dettmeyer, "Sudden cardiac death—update," *International journal of legal medicine*, vol. 135, pp. 483-495, 2021.
- [7] A. Rohila and A. Sharma, "Detection of sudden cardiac death by a comparative study of heart rate variability in normal and abnormal heart conditions," *Biocybernetics and Biomedical Engineering*, vol. 40, no. 3, pp. 1140-1154, 2020.
- [8] M. Shi et al., "Early detection of sudden cardiac death by using ensemble empirical mode decomposition-based entropy and classical linear features from heart rate variability signals," *Frontiers in Physiology*, vol. 11, p. 118, 2020.
- [9] O. Vargas-Lopez et al., "A new methodology based on EMD and nonlinear measurements for sudden cardiac death detection," *Sensors*, vol. 20, no. 1, p. 9, 2019.
- [10] R. Piña-Vega, M. Valtierra-Rodriguez, C. A. Perez-Ramirez, and J. P. Amezcua-Sanchez, "Early prediction of sudden cardiac death using fractal dimension and ecg signals," *Fractals*, vol. 29, no. 03, p. 2150077, 2021.
- [11] U. R. Acharya et al., "An integrated index for detection of sudden cardiac death using discrete wavelet transform and nonlinear features," *Knowledge-Based Systems*, vol. 83, pp. 149-158, 2015.
- [12] J. P. Amezcua-Sanchez, M. Valtierra-Rodriguez, H. Adeli, and C. A. Perez-Ramirez, "A novel wavelet transform-homogeneity model for sudden cardiac death prediction using ECG signals," *Journal of medical systems*, vol. 42, no. 10, p. 176, 2018.
- [13] M. Shi, H. Yu, and H. Wang, "Automated detection of sudden cardiac death by discrete wavelet transform of electrocardiogram signal," *Symmetry*, vol. 14, no. 3, p. 571, 2022.
- [14] M. A. Centeno-Bautista, A. H. Rangel-Rodriguez, A. V. Perez-Sanchez, J. P. Amezcua-Sanchez, D. Granados-Lieberman, and M. Valtierra-Rodriguez, "Electrocardiogram analysis by means of empirical mode decomposition-based methods and convolutional neural networks for sudden cardiac death detection," *Applied Sciences*, vol. 13, no. 6, p. 3569, 2023.
- [15] Sudden cardiac death database [Online] Available: <https://physionet.org/content/sddb/1.0.0/>
- [16] MIT-BIH Normal Sinus Rhythm Database [Online] Available: <https://physionet.org/content/nsrdb>
- [17] S. Li, W. Zhou, Q. Yuan, S. Geng, and D. Cai, "Feature extraction and recognition of ictal EEG using EMD and SVM," *Computers in biology and medicine*, vol. 43, no. 7, pp. 807-816, 2013.