

Classification of Normal and Abnormal Heart Sounds using Machine Learning Techniques

Sadeghi Nia, Parastoo¹ / Danandeh Hesar, Hamed^{2*}

¹ - M.Sc. Student, 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.2023.1987058.1821

Received: 9 January 2023

Revised: 27 February 2023

Accepted: 6 March 2023

KEYWORDS

Phonocardiogram
Particle Swarm
Optimization Algorithm
Feature Selection
Classification

ABSTRACT

Phonocardiography (PCG) signals provide valuable information about the heart valves. These auditory signals can be useful in the early diagnosis of heart diseases. Automatic heart sound classification has a promising potential in the field of heart pathology. In this research, a new method based on machine learning techniques is proposed for discriminating normal and abnormal heart sounds. In this method, first, the heart sounds are segmented into 4 main parts: S1, S2, systole and diastole segments. From these segments, statistical and time-frequency features are extracted for classification. Before classification, the distinctive features are selected using two approaches. In the first approach, the feature selection is accomplished using particle swarm optimization algorithm (PSO). In the second approach, we use Sequential Forward Feature Selection (SFFS) method. The proposed method was evaluated on the Physionet 2016 Challenge database using 10-fold cross-validation method. In this database, the number of normal and abnormal PCG signals are not balanced. Therefore, in this paper, the synthetic minority over-sampling technique (SMOTE) is applied to produce balanced data. The evaluation results showed that the proposed method can distinguish the normal heart sounds from abnormal ones with accuracy of 98.03% and sensitivity and specificity of 97.64% and 98.43% respectively.

*Corresponding Author

Address	Faculty of Biomedical Engineering, Sahand University of Technology, Tabriz, Iran		
Postal Code	51335-1996	Tel	+98-41-33458413
E-Mail	danandeh@sut.ac.ir	Fax	+98-41-33444292





طبقه‌بندی صداهای طبیعی از صداهای غیرطبیعی قلب با استفاده از روش‌های مبتنی بر یادگیری ماشین

صادقی‌نیا، پرستو^۱ / داندنده حصار، حامد^{۲*}

^۱ - دانشجوی 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.2023.1987058.1821

پذیرش: ۱۵ اسفند ۱۴۰۱

بازنگری: ۸ اسفند ۱۴۰۱

ثبت در سامانه: ۱۹ دی ۱۴۰۱

چکیده

واژه‌های کلیدی

سیگنال‌های فونوکاردیوگرافی (PCG) اطلاعات ارزشمندی در مورد عملکرد دریاچه‌های قلبی دارند. از این رو این سیگنال‌ها می‌توانند در تشخیص زودهنگام بیماری‌های قلبی مفید واقع شوند. طبقه‌بندی خودکار صدای قلب دارای پتانسیل امیدوارکننده‌ای در آسیب‌شناسی قلبی است. در این پژوهش روشی خودکار برای تشخیص صداهای طبیعی از غیرطبیعی قلب پیشنهاد شده است. در روش پیشنهادی ابتدا صداهای قلبی به چهار بخش صدای S1، S2، سیستول و دیاستول قطعه‌بندی شده و سپس ویژگی‌های زمانی آماری و زمانی فرکانسی از هر کدام از این بخش‌ها استخراج شده است. پیش از عملیات طبقه‌بندی داده‌ها، از دوره‌یافت برای انتخاب ویژگی‌های موثر استفاده شده است. انتخاب ویژگی در دوره‌یافت اول با استفاده از الگوریتم بهینه‌سازی ازدحام ذرات (PSO) و در دوره‌یافت دوم با استفاده از جست‌وجوی سلسله‌مراتبی (SFFS) انجام شده است. روش پیشنهادی روی پایگاه داده‌ی چالش ۲۰۱۶ فیزیوننت ارزیابی شده و در نهایت عملکرد آن با استفاده از روش اعتبارسنجی متقابل ۱۰-لایه‌ای مورد ارزیابی قرار گرفته است. هم‌چنین به دلیل نامتوازن بودن تعداد صداهای طبیعی نسبت به صداهای غیرطبیعی، از تکنیک بیش‌نمونه‌برداری اقلیت مصنوعی (SMOTE) برای تولید مجموعه‌ی داده‌های متعادل استفاده شده است. نتایج ارزیابی روی پایگاه داده نشان داده که روش پیشنهادی دارای صحت ۹۸/۰۳٪، حساسیت ۹۷/۶۴٪ و اختصاصیت ۹۸/۴۳٪ در تشخیص صداهای طبیعی از غیرطبیعی است.

فونوکاردیوگرام
الگوریتم بهینه‌سازی ازدحام ذرات
انتخاب ویژگی
طبقه‌بندی

*نویسنده‌ی مسئول

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

تلفن ۹۸-۴۱-۳۳۴۵۸۴۱۳

۵۱۳۳۵-۱۹۹۶

دورنگار ۹۸-۴۱-۳۳۴۴۴۲۹۲

danandeh@sut.ac.ir

پست الکترونیک



۱- مقدمه

امروزه بیماری‌های قلبی و عروقی به عنوان یکی از مهم‌ترین عوامل تهدید کننده‌ی سلامتی انسان‌ها محسوب شده و از جمله مهم‌ترین عامل‌های مرگ‌ومیر در جامعه هستند [۱]. بسیاری از بیماری‌ها و ناهنجاری‌های قلبی با استفاده از تکنیک‌های شنیداری قابل تشخیص و ارزیابی هستند به طوری که حتی در برخی از بیماری‌های مهم قلبی این تکنیک‌ها هم‌چنان از جمله روش‌های کارا و قابل اعتماد به حساب می‌آیند. امروزه در اکثر کشورهای پیش‌رفته و نیز در کشورهای در حال توسعه محققین در صدد پردازش این صداها و استخراج ویژگی‌های مهم آن‌ها به منظور پی بردن به برخی از بیماری‌ها می‌باشند [۲].

سیگنال صدای قلب^۱ (PCG) یک سیگنال غیرایستاد و شبه‌متناوب است. هر چرخه از این سیگنال به چهار بخش مهم با نام‌های سیگنال S_1 ، قطعه‌ی سیستول، سیگنال S_2 و قطعه‌ی دیاستول تقسیم می‌شود. در شکل (۱) این بخش‌ها برای یک نمونه‌ی سیگنال صدای قلب نشان داده شده است. در چند دهه‌ی گذشته آنالیز صدای قلب به طور گسترده مورد مطالعه قرار گرفته است. تحقیقات نشان می‌دهد که تکنیک‌های قطعه‌بندی و طبقه‌بندی خودکار صدای قلب پتانسیل غربال‌گری مناسبی را در آسیب‌شناسی بالینی قلب با هزینه‌ی نسبتاً کم دارند. از جمله‌ی این روش‌ها می‌توان به دسته‌بندی صداها یا ناهنجار از صداها یا طبیعی قلبی با استفاده از ضرایب کپسترال مل^۲ [۳، ۴]، تبدیل پراکندگی موجک [۵]، پوش موجک [۶] و سایر روش‌های مبتنی بر ویژگی‌های زمانی و فرکانسی [۷] اشاره کرد. هم‌چنین در زمینه‌ی طبقه‌بندی سیگنال‌های صوتی قلب به دو دسته‌ی طبیعی و غیرطبیعی، روش‌های مختلفی پیشنهاد شده که در آن‌ها از شبکه‌ی عصبی [۸]، ماشین بردار پشتیبان [۹، ۱۰] و شبکه‌ی عصبی کانولوشن [۸، ۱۱] برای شناسایی استفاده شده است.

با وجود این که در این روش‌ها از انواع مختلفی از ویژگی‌ها برای طبقه‌بندی صداها یا قلبی استفاده می‌شود، اما صحت مناسبی ندارند. در این مقاله به معرفی روشی برای تشخیص صداها یا طبیعی از غیرطبیعی قلبی پرداخته شده که دارای صحت، حساسیت و اختصاصیت مناسب‌تری نسبت به سایر روش‌های پیشنهادی حال حاضر در این زمینه است.


در بخش ۲ ابتدا به معرفی پایگاه داده‌ی مورد استفاده در این مقاله پرداخته شده، سپس به ترتیب نحوه‌ی قطعه‌بندی سیگنال‌های قلبی و ویژگی‌های استخراج شده توضیح داده شده، در ادامه دو روش پیشنهادی برای انتخاب ویژگی‌ها مبتنی بر جست‌وجوی سلسله‌مراتبی روبه‌جلو^۳ (SFFS) و الگوریتم بهینه‌سازی ازدحام ذرات^۴ (PSO) معرفی شده، سپس در مورد طبقه‌بندی‌های مورد استفاده در این مقاله صحبت شده و در انتها در مورد نحوه‌ی متوازن‌سازی داده‌ها بحث شده است. در بخش ۳ نتایج استفاده از روش پیشنهادی روی پایگاه داده‌ی چالش فیزیونت ۲۰۱۶ [۱۳] مورد ارزیابی قرار گرفته و بخش آخر به نتیجه‌گیری اختصاص داده شده است.

۲- مواد و روش‌ها

در این بخش به معرفی روش پیشنهادی برای طبقه‌بندی صداها یا طبیعی از غیرطبیعی پرداخته شده است. بلوک دیاگرام روش پیشنهادی در شکل (۲) نشان داده شده است. مراحل روش پیشنهادی بدین صورت بوده که سیگنال‌های فونوکاردیوگرام ابتدا در فرکانس ۱۰۰۰ هرتز باز نمونه‌برداری شده و سپس با استفاده از الگوریتم قطعه‌بندی پیشنهادی در مقاله‌ی [۱۴] به چهار ناحیه‌ی مختلف تقسیم شده است. پس از آن از هر کدام از ناحیه‌ها ویژگی‌های مختلف زمانی آماری، زمانی فرکانسی و آماری استخراج شده است. در مرحله‌ی بعد از دو ره‌یافت پیشنهادی جهت انتخاب ویژگی استفاده شده که در ره‌یافت اول از PSO و نرخ تفکیک‌پذیری فیشر^۵ (FDR) و در ره‌یافت دوم از SFFS برای انتخاب ویژگی بهره گرفته شده است. در مرحله‌ی بعد نیز ویژگی‌های برتر برای طبقه‌بندی به طبقه‌بندی‌های متداول داده شده است.

۲-۱- پایگاه داده

در این پژوهش از پایگاه داده‌ی چالش ۲۰۱۶ فیزیونت برای ارزیابی روش پیشنهادی استفاده شده است. این پایگاه داده به طور مستقل با جمع‌آوری بزرگ‌ترین بانک اطلاعاتی صدای قلب



شکل (۱) - سیگنال صدای قلب [۱۲]

^۱ Particle Swarm Optimization Algorithm

^۵ Fischer Discrimination Ratio

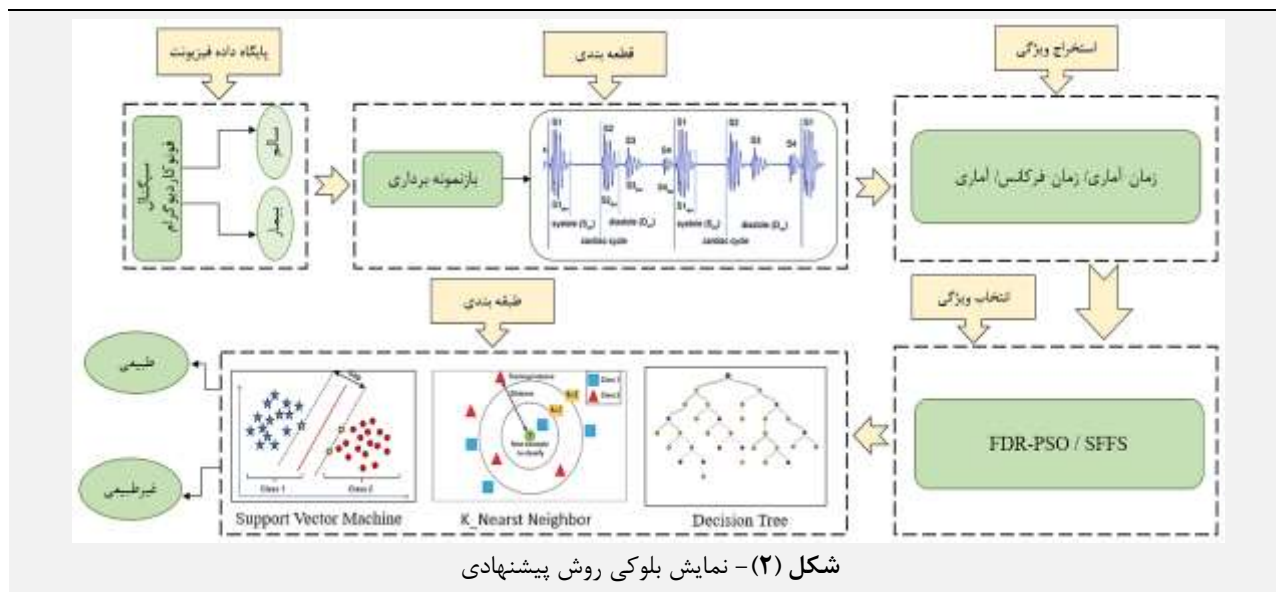
^۱ Phonocardiogram

^۲ Mel Cepstral Coefficients

^۳ Sequential Forward Feature Selection

علامت‌گذاری شده که شامل ۲۴۸۸ صدای ضبط شده طبیعی مربوط به فرد سالم و ۶۶۵ صدای ضبط شده غیرطبیعی مربوط به بیمارانی بوده که با انواع مختلفی از بیماری قلب و عروق مواجه بوده‌اند. تمام ضبط‌ها در فرکانس ۲۰۰۰ هرتز نمونه‌برداری شده است. جزئیات بیش‌تر در مورد این پایگاه داده در مقاله‌ی [۱۵] در دسترس است.

عمومی، از هشت منبع توسط هفت گروه به دست آمده است. این بانک اطلاعاتی شامل ۳۱۵۳ ضبط از ۷۶۴ فرد سالم و بیمار با انواع مختلفی از بیماری‌ها مانند بیماری دریچه‌ی قلب و بیماری عروق کرونر بوده که از افراد در سنین مختلف در هر دو محیط بالینی و غیربالینی جمع‌آوری شده است [۱۳]. تمام صداهای ضبط شده قلب به دو نوع طبیعی و غیرطبیعی



پوشه‌ی a موجود در پایگاه داده‌ی چالش ۲۰۱۶ فیزیوت آموزش داده شده است. داده‌های موجود در این پوشه علاوه بر سیگنال صدای قلبی حاوی سیگنال ECG^۴ نیز بوده که بهیچ صورت هم‌زمان در فرایند ثبت داده از بیماران ضبط شده است. در شکل (۳) عمل‌کرد الگوریتم طبقه‌بندی پیشنهادی در مقاله‌ی [۱۴] روی بخشی از ثبت (a0011) موجود در پایگاه داده‌ی چالش فیزیوت ۲۰۱۶ نشان داده شده است.

۳-۲- استخراج ویژگی

پس از طبقه‌بندی، ویژگی‌های مختلفی از نواحی یافته شده در سیگنال صوتی برای طبقه‌بندی استخراج شده است. هدف از استخراج ویژگی‌ها برای افزایش کارایی طبقه‌بند است. اگر ویژگی‌ها به درستی انتخاب نشود ممکن است عمل‌کرد طبقه‌بندی کاهش یابد. ویژگی‌هایی که در این تحقیق استخراج شده به سه دسته‌ی زیر تقسیم می‌شود.

۱- ویژگی‌های حوزه‌ی زمانی-آماری

تعداد ۲۸ ویژگی زمانی-آماری مربوط به طول‌های زمانی چهار ناحیه‌ی شاخص موجود در صداهای قلبی استخراج شده است

۲-۲- طبقه‌بندی سیگنال‌های PCG

طبقه‌بندی صداهای اصلی قلب^۱ (FHS) یک مرحله‌ی ضروری در تجزیه و تحلیل خودکار فونوکاردیوگرام است [۲]. در این پژوهش پیش از طبقه‌بندی، سیگنال‌های فونوکاردیوگرام ابتدا به فرکانس ۱۰۰۰ هرتز بازنمونه‌برداری شده است. محلی‌سازی دقیق FHS‌ها پیش‌نیازی برای شناسایی نواحی سیستولیک و دیاستولیک فونوکاردیوگرام است که امکان طبقه‌بندی بعدی موقعیت‌های پاتولوژی در این مناطق را فراهم می‌کند [۱۶]. این FHS‌ها به صدای اول قلب (S_1) و صدای دوم قلب (S_2) اشاره دارند [۱۷]. از آن‌جا که تمرکز این پژوهش روی طبقه‌بندی صداهای طبیعی از غیرطبیعی و نه خود فرایند طبقه‌بندی بوده، از الگوریتم پیشنهاد شده در مقاله‌ی [۱۴] برای طبقه‌بندی سیگنال‌های فونوکاردیوگرام استفاده شده است. این روش که یکی از روش‌های محبوب در طبقه‌بندی صداهای قلب بوده در سایر مطالعات در زمینه‌ی طبقه‌بندی صداهای قلبی نیز مورد استفاده قرار گرفته است. در این روش برای استخراج محل صداهای S_1 ، سیستول، S_2 و دیاستول از مدل نیمه‌پنهان مارکوف^۲ (HSMM) و رگرسیون لجستیک^۳ (LR) استفاده شده است. مدل HSSM فوق با استفاده از داده‌های موجود در

^۴ Logistic Regression

^۴ Electrocardiogram

^۱ Fundamental Heart Sounds

^۲ Hidden Semi-Markov Models

طیف توان، برای ماتریس سیستول ستون‌های ۲ تا ۳۰ چگالی طیف توان، برای ماتریس S₂ ستون‌های ۲ تا ۱۳ چگالی طیف توان و برای ماتریس دیاستول ستون‌های ۲ تا ۳۰ چگالی طیف توان انتخاب شده و به صورت ستونی از ماتریس‌های مربوطه میانگین‌گیری شده است. این مقادیر به صورت ویژگی‌های استخراج شده مورد استفاده قرار گرفته است.

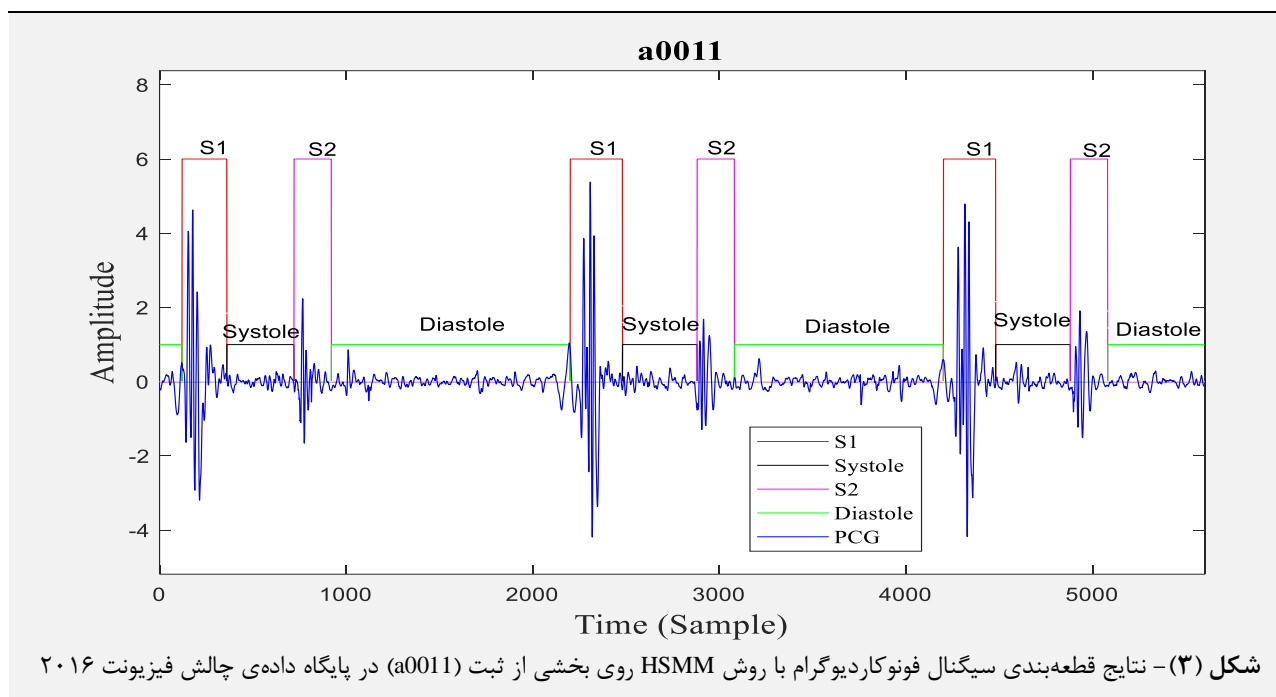
۳- ویژگی‌های انرژی

تعداد ۶ ویژگی انرژی نیز از ماتریس‌های فوق استخراج شده به طوری که پس از محاسبه‌ی انرژی قطعات صداهای قلبی، میانگین و انحراف معیار انرژی قطعات سیستول، دیاستول و نسبت انرژی قطعات S₁ و S₂ به کل انرژی هر چهار قطعه محاسبه شده و به عنوان ویژگی در نظر گرفته شده است. در مجموع ۱۱۶ ویژگی از هر صدای قلبی استخراج شده است.

[۱۸]. این ویژگی‌ها مربوط به میانگین و انحراف معیار مدت‌زمان هر چهار ناحیه‌ی صدای قلب، میانگین و انحراف معیار نسبت مدت‌زمان ناحیه‌ها به یک‌دیگر و میانگین و انحراف معیار نسبت فواصل ناحیه‌ها به طول هر ضربان قلب است. کشیدگی‌های طول‌های زمانی نواحی نیز به عنوان ویژگی در نظر گرفته شده است.

۲- ویژگی‌های حوزه‌ی زمانی-فرکانسی

تعداد ۸۲ ویژگی از چگالی‌های طیفی توان^۱ (PSD) نواحی قطعه‌بندی شده استخراج گردیده است. ابتدا تبدیل فوریه‌ی گسسته‌ی ۱۰۰ نمونه‌ای برای هر کدام از قطعات صداهای قلبی S₁، سیستول، S₂ و دیاستول محاسبه شده و پس از به دست آوردن چگالی طیف توان، در چهار ماتریس جداگانه ذخیره شده است. برای ماتریس مربوط به S₁ ستون‌های ۲ تا ۱۳ چگالی



نرخ تفکیک‌پذیری ویژگی‌ها را طوری افزایش دهد که هنگام استفاده از معیارهای بالا برای انتخاب ویژگی، عمل‌کرد طبقه‌بندها افزایش یابد. باید این نکته را خاطر نشان کرد که این مقاله یکی از اولین پژوهش‌ها در زمینه‌ی طبقه‌بندی صداهای قلبی بوده که از الگوریتم‌های فراابتکاری برای بهبود عمل‌کرد طبقه‌بندها استفاده کرده است. در ادامه به معرفی رهیافت دوم انتخاب ویژگی که بر اساس روش SFSS بوده، پرداخته شده است.

۲-۴- رهیافت‌های پیشنهادی برای انتخاب ویژگی

پس از استخراج ویژگی‌های مختلف می‌توان از معیارهای مختلفی برای انتخاب ویژگی استفاده کرد. معیارهایی مانند t -test، آنتروپی^۲ و باتاچارایا^۳ برای انتخاب ویژگی‌هایی که توزیع گوسی دارند و معیارهایی مانند ناحیه‌ی همگرایی^۴ (RoC) و ویلکاکسون^۵ با فرض این که ویژگی‌ها توزیع گوسی ندارند، برای انتخاب ویژگی مورد استفاده قرار می‌گیرند. در این بخش ابتدا به معرفی رهیافتی مبتنی بر الگوریتم ازدحام ذرات پرداخته که

^۱ Region of Convergence

^۵ Wilcoxon

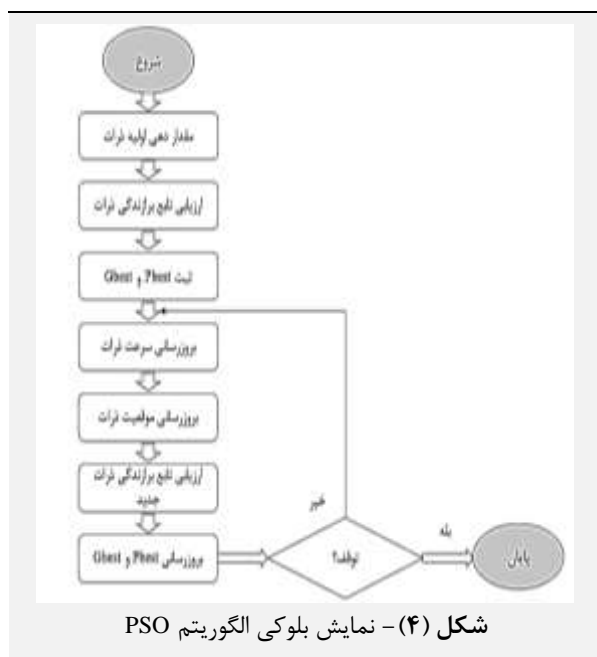
^۱ Power Spectral Density

^۲ Entropy

^۳ Bhattacharyya



الگوریتم‌های مبتنی بر هوش ازدحامی قرار دارد. این الگوریتم توسط جیمز کندی و راسل سی ابرهارت در سال ۱۹۹۵ [۲۱] با الهام از رفتار اجتماعی حیواناتی چون ماهی‌ها و پرندگان که در گروه‌های کوچک و بزرگ زندگی می‌کنند طراحی شده است. در الگوریتم PSO اعضای جمعیت (جواب‌ها) به طور مستقیم با هم در ارتباط بوده و از طریق تبادل اطلاعات با هم و یادآوری جواب‌های خوب گذشته به حل مسائل می‌پردازند. این الگوریتم برای انواع مسائل پیوسته و گسسته مناسب بوده و پاسخ‌های خوبی را برای انواع مختلفی از مسائل بهینه‌سازی ارائه می‌کند. بلوک دیاگرام این الگوریتم در شکل (۴) ارائه شده است.



مراحل بهینه‌سازی گام‌به‌گام برای الگوریتم PSO را می‌توان به صورت زیر توصیف کرد [۲۲].

۱- تنظیم پارامترهای بهینه‌سازی ازدحام ذرات

۲- ارزیابی تابع برازندگی ذرات

۳- به‌روزرسانی موقعیت و سرعت ذرات

۴- برای هر ذره، تابع برازندگی $x_i(t+1)$ با تابع برازندگی $P_{best_i}(t+1)$ مقایسه می‌شود. اگر مقدار تابع برازندگی این ذره کم‌تر از مقدار تابع برازندگی $P_{best_i}(t+1)$ باشد آن‌گاه $x_i(t+1)$ به عنوان بهترین تجربه‌ی شخصی ذره‌ی i -ام در مرحله‌ی $t+1$ قرار می‌گیرد، در غیر این صورت بهترین تجربه‌ی شخصی ذره‌ی i -ام در مرحله‌ی $t+1$ همان بهترین تجربه‌ی شخصی ذره‌ی i -ام در مرحله‌ی t است.

۵- در مرحله‌ی $t+1$ بهترین تجربه‌ی شخصی یک ذره به عنوان $G_{best}(t+1)$ انتخاب می‌شود که بهترین تجربه‌ی شخصی انتخاب

۲-۴-۱- ره‌یافت اول: انتخاب ویژگی با استفاده از نرخ

تفکیک‌پذیری فیشر

با فرض این که ویژگی‌ها توزیع گوسی دارند، ویژگی‌ها طوری تغییر داده شده است که نرخ تفکیک‌پذیری افزایش یابد. یکی از معیارهایی که نرخ تفکیک‌پذیری را بر اساس میانگین و واریانس محاسبه می‌کند، نرخ تفکیک‌پذیری فیشر (FDR) است. از این نرخ جهت تعیین مقدار تفکیک‌پذیری کلاس‌ها از یک‌دیگر و هم‌چنین میزان تاثیرگذاری هر کدام از ویژگی‌ها در میزان این تفکیک‌پذیری و نیز امکان ترکیب ویژگی‌ها برای تفکیک‌پذیری بهتر استفاده می‌شود [۱۹].

در روش فیشر جهت تفکیک بهتر دو کلاس از هم، ناحیه‌ی مشترک بین دو کلاس در تابع چگالی احتمال آن‌ها باید تا حد ممکن کوچک باشد و با توجه به مفهوم پارامترهای توابع گوسی، کاملا واضح است که هر چه اختلاف میانگین کلاس‌ها از هم بیش‌تر بوده و واریانس داخلی کلاس‌ها کوچک‌تر شود، ناحیه‌ی مشترک کوچک‌تر شده و کلاس‌ها تفکیک‌پذیری بهتری خواهند داشت. رابطه‌ی فیشر برای داده‌های با دو کلاس را می‌توان به صورت زیر بیان کرد [۲۰].

$$FDR = \frac{(\mu_1 - \mu_2)^2}{(\sigma_1^2 + \sigma_2^2)} \quad (1)$$

در این رابطه μ_1 و μ_2 به ترتیب مقدار میانگین نقاط داده در کلاس ۱ و ۲ و σ_1 و σ_2 به ترتیب واریانس‌های دو کلاس هستند.

۲-۴-۱-۱- بهبود انتخاب ویژگی با استفاده از الگوریتم

بهینه‌سازی ازدحام ذرات

معیار FDR برای چندین ویژگی به صورت زیر است.

$$FDR = \frac{(a^T * (\mu_1 - \mu_2) * (\mu_1 - \mu_2)^T * a)}{(a^T * \sum_1 * a + a^T * \sum_2 * a)} \quad (2)$$

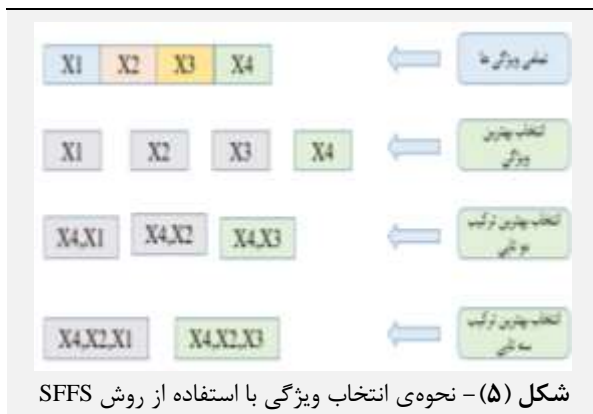
در این رابطه \sum_1 و \sum_2 ماتریس کوواریانس ویژگی‌های کلاس ۱ و ۲، μ_1 و μ_2 ماتریس میانگین ویژگی‌های کلاس ۱ و ۲ و a بردار ضرایب اهمیت^۱ ویژگی‌ها است که میزان تاثیر هر ویژگی را در افزایش معیار FDR مشخص می‌کند. مقادیر موجود در این بردار در حالت کلی مجهول هستند. برای پیدا کردن و بهینه‌سازی مقدار ضرایب مجهول در بردار a می‌توان از الگوریتم‌های بهینه‌سازی استفاده کرد. در این مطالعه از الگوریتم بهینه‌سازی ازدحام ذرات استفاده شده است.

الگوریتم بهینه‌سازی ازدحام ذرات (PSO) یکی از محبوب‌ترین الگوریتم‌های بهینه‌سازی هوشمند است که در حوزه‌ی

^۱ Importance Coefficient

۲-۴-۲- ره‌یافت دوم: انتخاب ویژگی با استفاده از روش جست‌وجوی سلسله‌مراتبی روبه‌جلو

روش جست‌وجوی سلسله‌مراتبی روبه‌جلو (SFFS) یکی از محبوب‌ترین روش‌های انتخاب ویژگی به صورت برداری است [۲۴]. این روش بهترین ترکیب ممکن را از میان ویژگی‌های موجود بر اساس طبقه‌بند مورد نظر انتخاب می‌کند به طوری که باعث افزایش عمل‌کرد آن طبقه‌بند شود. این روش یکی از ساده‌ترین و سریع‌ترین الگوریتم‌های جست‌وجوی حریصانه^۳ بوده که کار خود را با یک بردار که حاوی تنها یک ویژگی است شروع می‌کند. سپس ویژگی‌هایی را که می‌توانند به افزایش عمل‌کرد طبقه‌بند کمک کنند به صورت مرحله به مرحله به این بردار اضافه می‌کند تا زمانی که معیار خاتمه برآورده شود [۲۵]. بردار به دست آمده یک زیرفضا از کل فضای ویژگی بوده که به ازای آن عمل‌کرد طبقه‌بند نسبت به حالت اولیه‌ی استفاده از کل ویژگی‌ها بهبود یافته است. نحوه‌ی انتخاب ویژگی با استفاده از روش SFFS در شکل (۵) نشان داده شده است. در این مقاله از روش SFFS به عنوان ره‌یافت دوم پیشنهادی برای انتخاب ویژگی‌های مناسب برای طبقه‌بندی صداهای قلبی استفاده شده است. در بخش ۳، نتایج حاصل از استفاده از این روش برای بهبود عمل‌کرد طبقه‌بندها ارائه شده است.



۲-۵- طبقه‌بندی

در این مقاله برای طبقه‌بندی صداهای طبیعی و غیرطبیعی قلب از ۶ طبقه‌بند با نظارت شامل ماشین بردار پشتیبان^۴ (SVM)، ماشین بردار پشتیبان با کرنل تابع پایه‌ی شعاعی^۵ (RBF SVM)، k نزدیک‌ترین همسایه^۶ (KNN)، k نزدیک‌ترین همسایه‌ی وزن دار (WKNN)، درخت تصمیم^۷ (DT) و بیز ساده^۸ (NB) استفاده شده که در ادامه به توضیح هر کدام پرداخته شده است.

شده، در بین بهترین تجربه‌های شخصی تمام ذرات، کم‌ترین مقدار تابع برازندگی را داشته باشد.

۶- شرط اتمام الگوریتم بررسی می‌شود. اگر تعداد تکرار الگوریتم به حداکثر تعداد رسیده باشد، به عنوان مقدار جواب بهینه یا زیر بهینه اعلام شده و برنامه تمام می‌شود. در غیر این صورت مرحله‌ی دوم شروع می‌شود.

از نظر ریاضی، موقعیت و سرعت ذرات طبق روابط (۳) و (۴) به‌روز می‌شود [۲۳].

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (3)$$

$$v_i(t+1) = w V_i(t) + c_1 R_{1i} [P_{best_i}(t) - X_i(t)] + c_2 R_{2i} [G_{best}(t) - X_i(t)] \quad (4)$$

در این روابط t تعداد تکرارهای الگوریتم، w وزن اینرسی، $V_i(t)$ جابه‌جایی با توجه به سرعت فعلی ذره، $X_i(t)$ موقعیت ذره، $P_{best_i}(t)$ جابه‌جایی در جهت بهترین عمل‌کرد ذره‌ی i-ام تاکنون، $G_{best}(t)$ جابه‌جایی در جهت بهترین عمل‌کرد اطلاع‌رسانی شده از ذرات دیگر تاکنون، c_1 ضریب یادگیری شناختی، c_2 ضریب یادگیری اجتماعی و R_1 و R_2 دو عدد تصادفی با توزیع یک‌نواخت در بازه‌ی [۰, ۱] است.

در هر تکرار الگوریتم، ذره‌ای که بهترین جواب سرتاسری^۱ را دارد ثبت شده و در تکرار بعدی، الگوریتم با به‌روزرسانی موقعیت ذرات و مقایسه‌ی جواب‌ها با بهترین جواب یافت شده ادامه می‌یابد تا زمانی که شرط توقف حاصل گردد.

در الگوریتم بهینه‌سازی ازدحام ذرات پیشنهادی، از تابع برازندگی^۲ زیر استفاده شده است.

$$FitnessFunction = \frac{1}{FDR} = \frac{(a^T * \sum_1 * a + a^T * \sum_2 * a)}{(a^T * (\mu_1 - \mu_2) * (\mu_1 - \mu_2)^T * a)} \quad (5)$$

با تعریف تابع برازندگی به صورت رابطه‌ی (۵)، به حداقل رساندن تابع باعث به حداکثر رسیدن FDR می‌شود. هدف در این‌جا پیدا کردن بهترین مقادیر برای درایه‌های بردار a است به طوری که تابع برازندگی رابطه‌ی (۵) کمینه گردد.

پس از یافتن مقدار بهینه‌ی a، این بردار به صورت درایه به درایه در ویژگی‌های استخراج شده ضرب شده و سپس با استفاده از معیارهای t-test، آنتروپی و باتاچارایا عملیات انتخاب ویژگی انجام شده است.

^۱ Radial Basis Function

^۲ K-Nearest Neighborhood

^۳ Decision Tree

^۴ Naïve Bayes

^۵ Global Solution

^۶ Fitness Function

^۷ Greedy Search

^۸ Support Vector Machine



۲-۵-۱- ماشین بردار پشتیبان

ماشین بردار پشتیبان (SVM) یک مدل یادگیری ماشین با ناظر بوده که توسط ولادیمیر وپنیک در سال ۱۹۹۵ برای طبقه‌بندی داده‌های دو کلاسه‌ی خطی مطرح شده است. این طبقه‌بند بعدها توسط خود وپنیک برای مسائل غیرخطی و چندکلاسه توسعه داده شده است [۲۶]. ماشین بردار پشتیبان با توجه به داده‌های برچسب‌دار آموزشی، یک ابرفضای^۱ بهینه را ارائه کرده تا داده‌های جدید را به دسته‌های مختلف طبقه‌بندی کند. اساس طبقه‌بندی SVM طبقه‌بندی خطی داده‌ها است. ماشین بردار پشتیبان در واقع یک طبقه‌بند دودویی است که دو کلاس را با استفاده از یک مرز خطی با بیشینه‌سازی حاشیه از هم جدا می‌کند و به صورت رابطه‌ی (۶) بیان می‌شود [۲۷].

$$y(\mathbf{x}) = \mathbf{w}^T \varphi(\mathbf{x}) + \mathbf{b} \quad (6)$$

در این رابطه w بردار وزن، b پارامتر بایاس و φ تابع هسته است. عمل کرد SVM به نوع تابع هسته‌ی مورد استفاده در رابطه‌ی (۶) بستگی دارد. برای جداسازی داده‌های غیرخطی، استفاده از توابع هسته‌ی غیرخطی باعث بهبود در عمل کرد SVM می‌شود. یکی از گونه‌های متداول توابع غیرخطی، تابع پایه‌ی شعاعی (RBF) است. تابع RBF برای دو بردار x_i و x_j میزان شباهت یا نزدیک بودن آن‌ها به یکدیگر را محاسبه می‌کند. این هسته را می‌توان به صورت ریاضی در قالب رابطه‌ی (۷) بیان کرد.

$$k(x_i, x_j) = \exp(-\sigma \|x_i - x_j\|^2) \quad (7)$$

در این رابطه σ میزان واریانس است که به عنوان یک فراپارامتر در نظر گرفته می‌شود و $\|x_i - x_j\|^2$ فاصله‌ی اقلیدسی بین دو بردار x_i و x_j می‌باشد.

۲-۵-۲- k نزدیک‌ترین همسایگی

طبقه‌بند k نزدیک‌ترین همسایه (KNN) یک روش غیرپارامتریک بوده که از آن به طور گسترده در تجزیه و تحلیل سیگنال‌های زیست‌پزشکی استفاده شده است. در این روش برای برچسب‌گذاری هر داده، برچسب k عدد از داده‌هایی که نزدیک‌ترین فاصله را از داده دارند بررسی شده و پس از پیدا شدن برچسب اکثریت، آن برچسب به داده‌ی مزبور داده می‌شود. در الگوریتم KNN، k نمونه‌ی همسایه سهم یکسانی در رای‌گیری دارند. این در حالی است که همسایه‌های نزدیک‌تر باید سهم بیش‌تری در مقایسه با همسایه‌های دورتر داشته

باشند. از این رو الگوریتم دیگری با عنوان الگوریتم k نزدیک‌ترین همسایه‌ی وزن‌دار توسعه یافته است که در آن طبقه‌بندی بر اساس میزان شباهت همسایه‌های نزدیک به داده‌ی آزمایشی انجام می‌شود.

در الگوریتم پیشنهادی، مقدار $k=5$ در نظر گرفته شده و برای محاسبه‌ی وزن k همسایه‌ی انتخاب شده، از رابطه‌ی (۸) استفاده شده است.

$$W_{x_i, x_j} = \frac{1}{d(x_i, x_j)} \quad (8)$$

در این رابطه $d(x_i, x_j)$ فاصله‌ی دو بردار x_i و x_j از یکدیگر است.

۲-۵-۳- طبقه‌بند بیز ساده

طبقه‌بند بیز یک روش آماری قوی است که از تئوری بیز برای دسته‌بندی الگوها استفاده می‌کند. تئوری بیز یک روش آماری کمی است که بر اساس حداقل کردن هزینه‌های تصمیم‌گیری‌های مختلف عمل می‌کند. طبقه‌بند بیز طبق رابطه‌ی زیر، دانش اولیه و دانش اندازه‌گیری شده را به احتمالات پسین تبدیل کرده و از آن برای تصمیم‌گیری استفاده می‌کند. به این صورت که داده‌ی جدید به کلاسی تعلق دارد که بیش‌ترین احتمال پسین را نسبت به آن کلاس در مقایسه با سایر کلاس‌ها داشته باشد.

$$p(w_j | \mathbf{x}) = \frac{p(\mathbf{x} | w_j) p(w_j)}{p(\mathbf{x})} \quad (9)$$

در این رابطه $p(w_j)$ دانش اولیه در مورد هر کلاس (احتمال وقوع هر کلاس)، $p(\mathbf{x} | w_j)$ میزان شباهت داده‌ی ورودی به هر کلاس و $p(\mathbf{x})$ ثابت نرمالیزاسیون است [۲۸]. اگر برای تمام کلاس‌ها یکسان در نظر گرفته شود، آن‌گاه به این طبقه‌بند، طبقه‌بند بیز ساده گفته می‌شود.

۲-۵-۴- درخت تصمیم

یکی از پرکاربردترین الگوریتم‌های داده‌کاوی، الگوریتم درخت تصمیم (DT) است که از آن می‌توان برای پیش‌بینی و طبقه‌بندی استفاده کرد. درخت تصمیم یک روش رایج برای نشان دادن فرایند تصمیم‌گیری به وسیله‌ی ساختاری درخت مانند و شاخه‌دار است. به طور کلی درخت تصمیم روشی برای مدل‌سازی تصمیم‌ها، خروجی آن‌ها و نیز نگاشت تصمیم‌ها در یک ساختار درختی است. این الگوریتم روشی برای محاسبه‌ی

^۱ Hyper Plane

داده‌ها به ۵۱۰۴ بردار ویژگی افزایش پیدا کرده که شامل ۲۵۰۰ نمونه‌ی طبیعی و ۲۶۰۴ نمونه‌ی غیرطبیعی است.

۳- ارزیابی نتایج الگوریتم پیشنهادی

در این مطالعه برای ارزیابی عمل کرد طبقه‌بندها در الگوریتم پیشنهادی، از ارزیابی متقابل k -لایه^۳ ($K=10$) استفاده شده است. روند کار ارزیابی متقابل بدین صورت بوده که ۹۰ درصد داده‌ها به عنوان داده‌های آموزش و ۱۰ درصد داده‌ها به عنوان داده‌های آزمایش به کار گرفته شده که این روند در ۱۰ مرحله تکرار انجام شده تا جایی که از تمام داده‌ها هم در گروه آزمایش و هم در گروه آموزش استفاده شده و در نهایت متوسط نتایج ۱۰ بار تکرار به عنوان تخمین نهایی مورد استفاده قرار می‌گیرد.

۳-۱- معیارهای ارزیابی عمل کرد

تا کنون از روش‌های زیادی برای ارزیابی عمل کرد طبقه‌بندها استفاده شده که یکی از بهترین این روش‌ها محاسبه‌ی ماتریس درهم‌ریختگی^۴ روی مجموعه‌ی داده‌های آزمایشی و محاسبه‌ی شاخص‌های دقت، حساسیت و اختصاصیت از ماتریس درهم‌ریختگی برای ارزیابی نتایج طبقه‌بندی است. یک ماتریس درهم‌ریختگی برای طبقه‌بندی دو کلاس به صورت زیر است.

$$\text{Confusion Matrix} = \begin{bmatrix} TP & FN \\ FP & TN \end{bmatrix} \quad (10)$$

در این رابطه TP مثبت واقعی^۵ (تعداد نمونه‌هایی که به درستی بیمار تشخیص داده شده)، TN منفی واقعی^۶ (تعداد نمونه‌هایی که به درستی سالم تشخیص داده شده)، FP مثبت کاذب^۷ (تعداد نمونه‌هایی که به اشتباه بیمار تشخیص داده شده) و FN منفی کاذب^۸ (تعداد نمونه‌هایی که به اشتباه سالم تشخیص داده شده) است.

شاخص‌های حساسیت^۹ (Sen)، اختصاصیت^{۱۰} (Spe) و صحت^{۱۱} (Acc) به صورت زیر تعریف می‌شود.

$$Sen = \frac{TP}{TP + FN} \quad (11)$$

$$Spe = \frac{TN}{TN + FP} \quad (12)$$

$$Acc = \frac{TP + TN}{TN + FN + TP + FP} \quad (13)$$

پتانسیل موفقیت دنباله‌های مختلف تصمیم‌گیری در دست‌یابی به یک هدف خاص به حساب می‌آید. درخت تصمیم از گره‌های مختلفی ایجاد شده است. گره ریشه^۱ محل شروع درخت تصمیم است که معمولاً تمام مجموعه‌ی داده‌ی مساله را شامل می‌شود. گره‌های برگ^۲ نقطه‌ی پایانی هر شاخه‌ی درخت یا خروجی نهایی مجموعه‌ای از تصمیم‌ها هستند. هر شاخه‌ی درخت تصمیم در یادگیری ماشین فقط دارای یک گره برگ است. در درخت تصمیم برای پیش‌بینی کلاس‌های مورد نظر مجموعه‌ی داده‌ی مساله، رویکرد الگوریتم از گره ریشه‌ی درخت آغاز می‌شود. این الگوریتم مقادیر ویژگی‌های ریشه را با ویژگی‌های داده‌ها مقایسه کرده و بر اساس این مقایسه، شاخه‌ها را دنبال می‌کند و به گره بعدی می‌رود. برای گره بعدی، الگوریتم دوباره مقدار ویژگی داده‌ها را با زیرگره‌های دیگر مقایسه کرده و روند ایجاد درخت را پیش می‌برد. این رویکرد تا رسیدن به گره برگ یا گره انتهایی درخت ادامه پیدا می‌کند.

۲-۶- متوازن‌سازی داده‌ها

به دلیل این که تعداد ضابط‌های طبیعی با ضابط‌های غیرطبیعی در پایگاه داده‌ی مورد استفاده در این پژوهش برابر نیست، پس از استخراج ویژگی، از الگوریتم بیش‌نمونه‌برداری اقلیت مصنوعی^۳ (SMOTE) استفاده شده است تا پایگاه داده متعادل شود. در این روش نمونه‌های کلاس اقلیت با ایجاد نمونه‌های مصنوعی افزایش می‌یابد. این نمونه‌های مصنوعی با استفاده از نمونه‌های واقعی کلاس اقلیت تولید می‌شود.

در روش SMOTE نمونه‌های مصنوعی در چند گام تولید می‌شود. در گام نخست یک بردار ویژگی از کلاس اقلیت انتخاب شده و k نزدیک‌ترین همسایه‌ی آن انتخاب می‌شود. برای هر همسایه، اختلاف بین بردار ویژگی مورد نظر و آن همسایه محاسبه شده و در یک عدد تصادفی بین یک و صفر ضرب می‌شود. سپس مقدار حاصل شده به بردار ویژگی مورد نظر اضافه می‌شود. این کار باعث انتخاب یک نقطه‌ی تصادفی در امتداد خط وصل‌کننده‌ی بین دو بردار ویژگی از کلاس اقلیت خواهد شد. عملیات مذکور به شکل مشابه برای سایر بردارهای ویژگی نیز تکرار می‌شود تا بدین شکل تمام نمونه‌های مصنوعی مورد نیاز تولید شود [۲۹]. پس از اعمال الگوریتم SMOTE تعداد

^۳ False Positive

^۴ False Negative

^۵ Sensitivity

^۶ Specificity

^۷ Accuracy

^۱ Root Node

^۲ Leaf

^۳ K-Fold Cross Validation

^۴ Confusion Matrix

^۵ True Positive

^۶ True Negative



۳-۲- نتایج

در ادامه، نتایج ارزیابی روش پیشنهادی مبتنی بر دریافت اول و دریافت دوم توضیح داده شده است.

۳-۲-۱- نتایج دریافت اول


پیش از ارائه‌ی نتایج مربوط به دریافت اول، ابتدا ۱۱۶ ویژگی توسط طبقه‌بندهای مختلف ارزیابی شده است. در جدول (۱) نتایج به دست آمده به ازای طبقه‌بندهای مختلف ارائه شده است. همان‌طور که مشاهده می‌شود طبقه‌بند RBF SVM توانسته است به نتایج بالاتری نسبت به سایر طبقه‌بندها برسد.

جدول (۱) - نتایج حاصل از دریافت اول (۱۱۶ ویژگی)

طبقه‌بند	صحت	حساسیت	اختصاصیت
Bayes	۷۵/۵۰	۷۰/۲۷	۸۰/۴۹
Tree	۷۱/۹۶	۵۸/۷۴	۸۴/۶۷
SVM-RBF	۹۵/۲۷	۹۲/۶۶	۹۷/۷۶
SVM	۸۶/۶۷	۸۲/۳۸	۹۰/۷۵
KNN	۹۱/۴۹	۸۳/۲۱	۹۹/۴۲
KNN_Weighted	۹۱/۳۵	۸۲/۴۸	۹۹/۸۴

در مرحله‌ی بعد برای بهبود نتایج جدول (۱) از معیارهای مختلف انتخاب ویژگی مانند t-test، آنتروپی و باتاچاریا با فرض این که ویژگی‌ها توزیع گوسی دارند استفاده شده است. هم‌چنین با معیارهایی مانند RoC و ویلکاکسون با فرض این که

ویژگی‌ها توزیع گوسی ندارند، نتایج طبقه‌بندها یک بار دیگر نیز مورد بررسی قرار گرفته است. در مرحله بعد برای بهبود نتایج مرحله‌ی قبل، با فرض این که ویژگی‌ها توزیع گوسی دارند، از انتخاب ویژگی مبتنی بر FDR و PSO استفاده شده است. در شکل (۶) مقادیر درایه‌های بردار a برای ۱۱۶ ویژگی استخراج شده نشان داده شده است. برای نمایش بهتر، این ضرایب به صورت نرمالیزه شده در شکل (۶) نشان داده شده است. در جدول‌های (۲) تا (۴) تاثیر استفاده از دریافت اول در بهبود عمل‌کرد طبقه‌بندها قابل مشاهده است. به عنوان مثال در جدول (۲) مشاهده می‌شود که با استفاده از معیار انتخاب ویژگی t-test و پس از اعمال الگوریتم پیشنهادی مبتنی بر PSO و FDR، طبقه‌بند RBF SVM با ۱۱۴ ویژگی توانسته به صحت ۹۵/۵۴٪، حساسیت ۹۳/۱۰٪ و اختصاصیت ۹۷/۸۷٪ دست یابد که نسبت به سایر طبقه‌بندها از نتایج بالاتری برخوردار است. در جدول (۳) مشاهده می‌شود که عمل‌کرد طبقه‌بندهای KNN و WKNN با اعمال الگوریتم دریافت اول بهبود یافته است. در جدول (۴) نیز با استفاده از دریافت اول عمل‌کرد طبقه‌بندهای DT و NB بهبود یافته است. با نگاهی به نتایج جدول‌های (۲) تا (۴) مشاهده می‌شود که بهترین نتایج با استفاده از اعمال دریافت اول به طبقه‌بند RBF SVM استفاده از معیار انتخاب ویژگی t-test به دست آمده است. طبقه‌بند مذکور به عنوان روش پیشنهادی اول در جدول (۶) با الگوریتم‌های سایر مراجع مقایسه شده است.



شکل (۶) - مقادیر نرمالیزه شده‌ی ضرایب a



جدول (۲) - نتایج حاصل از اعمال الگوریتم ره‌یافت اول برای بهبود عمل کرد طبقه‌بندهای SVM و SVM-RBF

روش رتبه‌بندی ویژگی‌ها					معیار ارزیابی	روش
Wilcoxon	ROC	Bhattacharyya	Entropy	T-Test		
۸۶/۸۶	۸۶/۹۴	۸۶/۶۴	۸۶/۶۸	۸۶/۶۴	صحت (%)	SVM
۸۲/۷۰	۸۲/۳۸	۸۲/۳۸	۸۲/۴۰	۸۲/۳۸	حساسیت (%)	
۹۰/۴۸	۹۰/۸۴	۹۰/۷۵	۹۰/۸۳	۹۰/۷۵	اختصاصیت (%)	
۸۹/۷۲	۸۶/۹۴	۸۶/۸۲	۸۶/۸۴	۸۶/۷۰	صحت (%)	PSO-SVM
۸۳/۱۳	۸۲/۸۸	۸۳/۰۳	۸۲/۸۸	۸۲/۸۵	حساسیت (%)	
۹۰/۲۰	۹۰/۸۴	۹۰/۴۷	۹۰/۶۷	۹۰/۶۵	اختصاصیت (%)	
۹۵/۲۷	۹۵/۳۵	۹۵/۳۵	۹۵/۳۵	۹۵/۵۰	صحت (%)	SVM-RBF
۹۲/۶۶	۹۲/۸۲	۹۲/۶۹	۹۲/۶۲	۹۲/۹۳	حساسیت (%)	
۹۷/۷۶	۹۷/۷۵	۹۷/۸۷	۹۷/۹۵	۹۷/۹۴	اختصاصیت (%)	
۹۵/۴۷	۹۵/۴۳	۹۵/۴۳	۹۵/۴۱	۹۵/۵۴	صحت (%)	PSO-SVM-RBF
۹۲/۷۸	۹۲/۸۷	۹۲/۷۹	۹۲/۶۲	۹۳/۱۰	حساسیت (%)	
۹۸/۰۲	۹۷/۸۷	۹۷/۹۵	۹۸/۰۶	۹۷/۸۷	اختصاصیت (%)	

جدول (۳) - نتایج حاصل از اعمال الگوریتم ره‌یافت اول برای بهبود عمل کرد طبقه‌بندهای KNN و KNN وزن‌دار

روش رتبه‌بندی ویژگی‌ها					معیار ارزیابی	روش
Wilcoxon	ROC	Bhattacharyya	Entropy	T-Test		
۹۱/۹۴	۹۱/۶۰	۹۲/۰۱	۹۱/۸۰	۹۲/۰۹	صحت (%)	KNN
۸۳/۶۵	۸۲/۹۸	۸۳/۸۰	۸۳/۳۳	۸۳/۹۷	حساسیت (%)	
۹۹/۸۴	۹۹/۸۸	۹۹/۸۸	۹۹/۹۲	۹۹/۸۸	اختصاصیت (%)	
۹۲/۰۷	۹۱/۸۸	۹۲/۱۱	۹۱/۸۴	۹۲/۱۱	صحت (%)	PSO-KNN
۸۳/۸۴	۸۳/۵۴	۸۴/۰۱	۸۳/۴۷	۸۴/۰۱	حساسیت (%)	
۹۹/۹۶	۹۹/۸۸	۹۹/۸۸	۹۹/۸۴	۹۹/۸۸	اختصاصیت (%)	
۹۲/۰۵	۹۱/۸۸	۹۲/۰۵	۹۱/۸۰	۹۲/۱۱	صحت (%)	KNN-Weighted
۸۳/۸۵	۸۳/۵۴	۸۳/۸۸	۸۳/۳۷	۸۴/۰۱	حساسیت (%)	
۹۹/۹۲	۹۹/۸۸	۹۹/۸۸	۹۹/۸۸	۹۹/۸۸	اختصاصیت (%)	
۹۲/۱۱	۹۲/۱۱	۹۲/۱۱	۹۲/۱۱	۹۲/۱۱	صحت (%)	PSO-KNN-Weighted
۸۴/۰۱	۸۴/۰۱	۸۴/۰۱	۸۴/۰۱	۸۴/۰۱	حساسیت (%)	
۹۹/۸۸	۹۹/۸۸	۹۹/۸۸	۹۹/۸۸	۹۹/۸۸	اختصاصیت (%)	

جدول (۴) - نتایج حاصل از اعمال الگوریتم ره‌یافت اول برای بهبود عمل کرد طبقه‌بندهای DT و NB

روش رتبه‌بندی ویژگی‌ها					معیار ارزیابی	روش
Wilcoxon	ROC	Bhattacharyya	Entropy	T-Test		
۷۸/۷۶	۷۸/۹۲	۷۸/۹۲	۷۸/۹۲	۷۸/۹۲	صحت (%)	DT
۷۵/۰۷	۷۱/۶۶	۷۱/۶۶	۷۱/۶۶	۷۱/۶۶	حساسیت (%)	
۸۲/۲۱	۸۵/۸۹	۸۵/۸۹	۸۵/۸۹	۸۵/۸۹	اختصاصیت (%)	
۷۸/۹۲	۷۸/۹۲	۷۹/۲۱	۷۸/۹۲	۷۹/۴۷	صحت (%)	PSO-DT
۷۱/۶۶	۷۱/۶۶	۷۵/۶۵	۷۱/۶۶	۷۵/۲۶	حساسیت (%)	
۸۵/۸۹	۸۵/۸۹	۸۲/۶۷	۸۵/۹۷	۸۶/۱۴	اختصاصیت (%)	
۷۵/۵۰	۷۵/۴۵	۷۵/۵۴	۷۵/۵۰	۷۵/۵۰	صحت (%)	NB
۷۰/۲۷	۷۰/۱۱	۷۰/۶۸	۷۰/۲۷	۷۰/۲۷	حساسیت (%)	
۸۰/۴۹	۸۰/۵۳	۸۰/۱۹	۸۰/۴۹	۸۰/۴۹	اختصاصیت (%)	
۷۵/۵۰	۷۵/۵۰	۷۵/۵۸	۷۵/۶۲	۷۵/۵۰	صحت (%)	PSO-NB
۷۰/۵۹	۷۰/۲۷	۷۰/۴۴	۷۰/۲۶	۷۰/۲۷	حساسیت (%)	
۸۰/۲۰	۸۰/۴۹	۸۰/۴۸	۸۰/۷۳	۸۰/۴۹	اختصاصیت (%)	



۳-۲-۲- نتایج حاصل از ره‌یافت دوم

در ره‌یافت دوم روش پیشنهادی، ویژگی‌های استخراج شده با استفاده از طبقه‌بندهای SVM، RBF SVM، KNN، WKNN، DT و NB با کمک روش انتخاب ویژگی SFFS مدل‌سازی شده است. نتایج حاصل از این ره‌یافت به طور جداگانه در جدول (۵)

ارائه شده است. مشاهده می‌شود که RBF SVM با ترکیب ۶۶ ویژگی به صحت ۹۸/۰۳٪، حساسیت ۹۷/۶۴٪ و اختصاصیت ۹۸/۴۳٪ دست یافته است. این طبقه‌بند به عنوان روش پیشنهادی دوم در جدول (۶) با الگوریتم‌های سایر مراجع مقایسه شده است.

جدول (۵) - نتایج حاصل از ره‌یافت دوم

طبقه‌بند	صحت (%)	حساسیت (%)	اختصاصیت (%)	ترکیب ویژگی‌ها
SFFS-SVM	۸۹/۴۱	۸۷/۰۵	۹۱/۷۶	۷۲
SFFS-SVM-RBF	۸۹/۰۳	۹۷/۶۴	۹۸/۴۳	۶۶
SFFS-KNN	۹۵/۶۸	۹۱/۳۷	۱۰۰	۳۷
SFFS-KNN-Weighted	۹۵/۴۹	۹۰/۹۸	۱۰۰	۲۱
SFFS-Bayes	۸۳/۷۲	۸۶/۶۶	۸۰/۷۸	۳۷
SFFS-DT	۷۰/۹۸	۵۸/۴۳	۶۷/۸۵	به طور یک‌نواخت

۳-۳- مقایسه‌ی الگوریتم‌های پیشنهادی با

الگوریتم‌های سایر مقالات

در ادامه، عمل‌کرد الگوریتم ارائه شده در این مقاله با عمل‌کرد بهترین روش‌های ارائه شده در چالش فیزیونت ۲۰۱۶ (که بالاترین امتیازها را کسب کرده‌اند) و نیز سایر روش‌های ارائه شده در مقالات معتبر که از این پایگاه داده استفاده کرده‌اند،

مقایسه شده است. نتایج جدول (۶) حاکی از عمل‌کرد بهتر روش پیشنهادی در هر دو ره‌یافت در مقایسه با بهترین روش‌ها است. با وجود این که نتایج ره‌یافت اول نسبت به ره‌یافت دوم مبتنی بر SFFS کمی ضعیف‌تر بوده، اما باز هم نتایج بهتری نسبت به سایر روش‌های مقالات دیگر در زمینه‌ی طبقه‌بندی صداهای طبیعی از صداهای غیرطبیعی قلبی ارائه کرده است.

جدول (۶) - مقایسه‌ی نتایج نهایی روش‌های پیشنهادی و بهترین روش‌های ارائه شده در چالش ۲۰۱۶ فیزیونت

ارزیابی روش‌های ارائه شده (%)			روش
ویژگی	حساسیت	صحت	
۷۷/۸۱	۹۴/۲۴	۸۶/۰۲	پوتس و هم‌کاران [۳۰]
۸۰/۴۸	۸۸/۴۸	۸۴/۴۸	هومسی و هم‌کاران [۱۸]
۸۲/۰۵	۹۱/۸۷	۸۶/۹۶	نوگیرا و هم‌کاران (استفاده از تنها بخشی از پایگاه داده‌ی فیزیونت ۲۰۱۶) [۳۱]
۸۱/۶۹	۹۳/۲۷	۸۷/۶۱	حاضری و هم‌کاران [۳۲]
۹۳	۹۵	۹۴	چن و هم‌کاران [۸]
۹۰/۶۵	۹۶/۶۲	۹۲/۲۳	می و هم‌کاران [۵]
۹۷/۸۷	۹۳/۱۰	۹۵/۵۴	روش پیشنهادی اول
۹۸/۴۳	۹۷/۶۴	۹۸/۰۳	روش پیشنهادی دوم

۴- نتیجه‌گیری

هدف این مطالعه ارائه‌ی یک روش جدید برای طبقه‌بندی صداهای قلبی به کلاس‌های طبیعی و غیرطبیعی است. برای این منظور ویژگی‌های استخراج شده ابتدا با طبقه‌بندهای مختلف مورد ارزیابی قرار گرفته و سپس در مرحله‌ی انتخاب ویژگی برای بهبود نتایج از ترکیب الگوریتم FDR-PSO استفاده شده است. با به کارگیری الگوریتم FDR-PSO تمام نتایج طبقه‌بندهای مختلف بهبود یافته است. بالاترین نتایج ره‌یافت

اول مربوط به RBF SVM است. در ره‌یافت پیشنهادی دوم برای رسیدن به نتایج موثر طبقه‌بندی، از انتخاب ویژگی SFFS با طبقه‌بندهای SVM، RBF SVM، WKNN، NB و DT استفاده شده و در نهایت با استفاده از معیارهای ارزیابی، الگوریتم پیشنهادی مورد ارزیابی قرار گرفته است.

در این مقاله با تعداد ویژگی‌های محدود (۱۱۴) ویژگی در ره‌یافت اول و ۶۶ ویژگی در ره‌یافت دوم، داده‌های موجود در پایگاه فیزیونت به خوبی طبقه‌بندی شده است. نتایج به دست



- modified frequency wavelet transform and convolutional neural network," *Medical & Biological Engineering & Computing*, vol. 58, no. 9, pp. 2039-2047, 2020.
- [9] J. J. G. Ortiz, C. P. Phoo, and J. Wiens, "Heart sound classification based on temporal alignment techniques," in *2016 computing in cardiology conference (CinC)*, 2016: IEEE, pp. 589-592 .
- [10] M. Tschannen, T. Kramer, G. Marti, M. Heinzmann, and T. Wiatowski, "Heart sound classification using deep structured features," in *2016 Computing in Cardiology Conference (CinC)*, 2016: IEEE, pp. 565-568 .
- [11] F. Li, H. Tang, S. Shang, K. Mathiak, and F. Cong, "Classification of heart sounds using convolutional neural network," *Applied Sciences*, vol. 10, no. 11, p. 3956, 2020.
- [12] M. Nabih-Ali, E.-S. A. El-Dahshan, and A. S. Yahia, "Heart diseases diagnosis using intelligent algorithm based on PCG signal analysis," *International Journal of Biology and Biomedicine*, vol. 2, 2017.
- [13] G. D. Clifford et al., "Classification of normal/abnormal heart sound recordings: The PhysioNet/Computing in Cardiology Challenge 2016," in *2016 Computing in cardiology conference (CinC)*, 2016: IEEE, pp. 609-612 .
- [14] D. B. Springer, L. Tarassenko, and G. D. Clifford, "Logistic regression-HSMM-based heart sound segmentation," *IEEE transactions on biomedical engineering*, vol. 63, no. 4, pp. 822-832, 2015.
- [15] C. Liu et al., "An open access database for the evaluation of heart sound algorithms," *Physiological Measurement*, vol. 37, no. 12, p. 2181, 2016.
- [16] A. Leatham, *Auscultation of the Heart and Phonocardiography*. Churchill London, 1970.
- [17] J. A. Innes, A. R. Dover, and K. Fairhurst, *Macleod's clinical examination*. Elsevier Health Sciences, 2018.
- [18] M. N. Homsy et al., "Automatic heart sound recording classification using a nested set of ensemble algorithms," in *2016 Computing in Cardiology Conference (CinC)*, 2016: IEEE, pp. 817-820 .
- [19] S. Wang, D. Li, Y. Wei, and H. Li, "A feature selection method based on fisher's discriminant ratio for text sentiment classification," in *International Conference on Web Information Systems and Mining*, 2009: Springer, pp. 88-97 .
- [20] S. Sarabi, M. Asadnejad, and S. Rajabi, "Using neural network for drowsiness detection based on EEG signals and optimization in the selection of its features using genetic algorithm,"

آمده از ارزیابی‌ها نشان داده که در دریافت اول با معیار t-test و RBF SVM بهترین نتایج (صحت ۹۵/۵۴٪، حساسیت ۹۳/۱۰٪ و اختصاصیت ۹۷/۸۷٪) به دست آمده است. در دریافت دوم نیز طبقه‌بند RBF SVM در مقایسه با سایر روش‌ها با ترکیب ۶۶ ویژگی به صحت ۹۸/۰۳٪، حساسیت ۹۷/۶۴٪ و اختصاصیت ۹۸/۴۳٪ رسیده است. همچنین در دریافت دوم طبقه‌بندهای KNN و WKNN به اختصاصیت ۱۰۰٪ رسیده‌اند. طبق نتایج به دست آمده از لحاظ صحت، حساسیت و اختصاصیت مشاهده شده که الگوریتم پیشنهادی دریافت دوم با استفاده از طبقه‌بند RBF SVM در مقایسه با سایر روش‌ها به نتایج بالاتری دست یافته است.

۵- مراجع

- [1] K. Rezaee and J. Haddadnia, "Design and performance evaluation of intelligent system to segregate and classify the phonocardiograph abnormalities using matched filter and multilayer perceptron-back propagation neural networks," *Pajoohandeh Journal*, vol. 18, no. 5, pp. 277-286, 2013.
- [2] A. K. Abbas and R. Bassam, "Phonocardiography signal processing," *Synthesis Lectures on Biomedical Engineering*, vol. 4, no. 1, pp. 1-194, 2009.
- [3] T. Nilanon, J. Yao, J. Hao, S. Purushotham, and Y. Liu, "Normal/abnormal heart sound recordings classification using convolutional neural network," in *2016 computing in cardiology conference (CinC)*, 2016: IEEE, pp. 585-588 .
- [4] J. Rubin, R. Abreu, A. Ganguli, S. Nelaturi, I. Matei, and K. Sricharan, "Classifying heart sound recordings using deep convolutional neural networks and mel-frequency cepstral coefficients," in *2016 Computing in cardiology conference (CinC)*, 2016: IEEE, pp. 813-816 .
- [5] N. Mei, H. Wang, Y. Zhang, F. Liu, X. Jiang, and S. Wei, "Classification of heart sounds based on quality assessment and wavelet scattering transform," *Computers in Biology and Medicine*, vol. 137, p. 104814, 2021.
- [6] M. A. Goda and P. Hajas, "Morphological determination of pathological PCG signals by time and frequency domain analysis," in *2016 computing in cardiology conference (CinC)*, 2016: IEEE, pp. 1133-1136 .
- [7] M. Milani, P. E. Abas, L. C. De Silva, and N. D. Nanayakkara, "Abnormal heart sound classification using phonocardiography signals," *Smart Health*, vol. 21, p. 100194, 2021.
- [8] Y. Chen, S. Wei, and Y. Zhang, "Classification of heart sounds based on the combination of the

- [27] C. M. Bishop and N. M. Nasrabadi, Pattern recognition and machine learning (no. 4). Springer, 2006.
- [28] N. Dey, A. S. Ashour, F. Shi, and V. E. Balas, Soft Computing Based Medical Image Analysis. Academic Press, 2018.
- [29] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, "SMOTE: synthetic minority over-sampling technique," Journal of artificial intelligence research, vol. 16, pp. 321-357, 2002.
- [30] C. Potes, S. Parvaneh, A. Rahman, and B. Conroy, "Ensemble of feature-based and deep learning-based classifiers for detection of abnormal heart sounds," in 2016 computing in cardiology conference (CinC), 2016: IEEE, pp. 621-624.
- [31] D. M. Nogueira, C. A. Ferreira, and A. M. Jorge, "Classifying heart sounds using images of MFCC and temporal features," in EPIA Conference on Artificial Intelligence, 2017: Springer, pp. 186-203.
- [32] H. Hazeri, P. Zarjam, and G. Azemi, "Classification of normal/abnormal PCG recordings using a time-frequency approach," Analog Integrated Circuits and Signal Processing, vol. 109, no. 2, pp. 459-465, 2021.
- Innovaciencia Facultad de Ciencias Exactas Físicas y Naturales, vol. 8, no. 1, pp. 1-9, 2020.
- [21] Y. Shi, "Particle swarm optimization," IEEE connections, vol. 2, no. 1, pp. 8-13, 2004.
- [22] P. Umapathy, C. Venkateshaiah, and M. S. Arumugam, "Particle swarm optimization with various inertia weight variants for optimal power flow solution," Discrete Dynamics in Nature and Society, vol. 2010, 2010.
- [23] Y. He, W. J. Ma, and J. P. Zhang, "The parameters selection of PSO algorithm influencing on performance of fault diagnosis," in MATEC Web of conferences, 2016, vol. 63: EDP Sciences, p. 02019.
- [24] F. Shirbani and H. Soltanian Zadeh, "Fast SFFS-based algorithm for feature selection in biomedical datasets," AUT Journal of Electrical Engineering, vol. 45, no. 2, pp. 43-56, 2013.
- [25] B. Ashok and P. Aruna, "Comparison of Feature selection methods for diagnosis of cervical cancer using SVM classifier," Int. J. Eng. Res. Appl, vol. 6, pp. 94-99, 2016.
- [26] L. Wang, Support vector machines: theory and applications. Springer Science & Business Media, 2005.