این مقاله در مرحله ویراستاری بوده و نسخه نهایی آن به زودی در سایت مجله قرار داده خواهد شد

Published by: Iranian Society for Biomedical Engineering / www.isbme.ir

Iranian Journal of Biomedical Engineering

www.ijbme.org / P-ISSN: 2008-5869 / E-ISSN: 8006-9685

Volume 16, Issue 3, Autumn 2022, 271-287

Classification of Normal and Abnormal Heart Sounds Using Machine Learning Techniques

Sadeghi Nia, Parastoo [1] / Danandeh Hesar, Hamed [2*]

[1] - Msc 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%, 98.43%respectively.

[*]**Corresponding Author**

Address	Group Office or Laboratory, Department, University, City, Country		
Postal Code	xxxxx-xxxxx	**Tel**	*+xx-xx-xxxxxxxx*
E-Mail	*auther2@xxx.ac.xx*	**Fax**	*+xx-xx-xxxxxxxx*

این مقاله در مرحله ویراستاری بوده و نسخه نهایی آن به زودی در سایت مجله قرار داده خواهد شد

ناشر: انجمن مهندسی پزشکی ایران / www.isbme.ir

مجله‌ی مهندسی پزشکی زیستی

شاپای چاپی: ۵۸۶۹-۲۰۰۸ / شاپای الکترونیکی: ۹۶۸۵-۸۰۰۶ / www.ijbme.org

دوره: ۱۶، شماره: ۳، پاییز ۱۴۰۱، ۲۷۱-۲۸۷

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

صادقی نیا، پرستو [۱] / داننده حصار، حامد [۲]*

[۱] —دانشجوی ارشد مهندسی پزشکی بیوالکتریک، دانشکده مهندسی پزشکی، دانشگاه صنعتی سهند تبریز، تبریز

[۲] — استادیار، گروه بیوالکتریک، دانشکده مهندسی پزشکی، دانشگاه صنعتی سهند، تبریز

مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/ijbme.2023.1987058.1821

ثبت در سامانه: ۱۹ دی ۱۴۰۱ | بازنگری: ۸ اسفند ۱۴۰۱ | پذیرش: ۱۵ اسفند ۱۴۰۱

واژه‌های کلیدی

فونوکاردیوگرام،
الگوریتم بهینه‌سازی ازدحام ذرات،
انتخاب ویژگی،
طبقه‌بندی

چکیده

سیگنال‌های فونوکاردیوگرافی (***PCG***)، اطلاعات ارزشمندی را در مورد عملکرد دریچه‌های قلبی دارند. ازاین‌رو، این سیگنال‌ها در تشخیص زودهنگام بیماری‌های قلبی می‌توانند 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 گردیده است. در روش پیشنهادی ابتدا صداهای قلبی به چهار بخش صدای ***S1***، ***S2***، سیستول و دیاستول قطعه‌بندی می‌گردند. سپس ویژگی‌های زمانی آماری و زمانی فرکانسی از هرکدام از این بخش‌ها استخراج می‌گردد. قبل از عملیات طبقه‌بندی داده‌ها، از دو رهیافت برای انتخاب ویژگی‌های مؤثر استفاده‌شده است. در رهیافت اول، انتخاب ویژگی با استفاده از الگوریتم بهینه‌سازی ازدحام ذرات (***PSO***) و در رهیافت دوم با استفاده از جستجوی سلسله مراتبی (***SFFS***) انجام می‌گردد. روش پیشنهادی بر روی پایگاه داده چالش ۲۰۱۶ فیزیونت ارزیابی گردید و در نهایت عملکرد روش پیشنهادی با استفاده از روش اعتبارسنجی متقابل۱۰لایه‌ای مورد ارزیابی قرار گرفت. همچنین، به علت ناموازن بودن تعداد صداهای طبیعی نسبت به صداهای غیرطبیعی، از تکنیک بیش‌نمونه‌برداری اقلیت مصنوعی (***SMOTE***) برای تولید مجموعه داده‌های متعادل استفاده گردید. نتایج ارزیابی روی پایگاه داده فوق‌الذکر نشان دادند که روش پیشنهادی دارای صحت ۹۸/۰۳ درصد، حساسیت ۹۷/۶۴ درصد و اختصاصیت ۹۸/۴۳ درصد در تشخیص صداهای طبیعی از غیرطبیعی می‌باشد.

***نویسنده‌ی مسئول**

نشانی	گروه دفتر یا آزمایشگاه، دانشکده، دانشگاه، شهر، کشور		
کد پستی	؟؟؟؟؟-؟؟؟؟؟	**تلفن**	+؟؟-؟؟-؟؟؟؟؟؟؟؟
پست الکترونیک	auther2@xxx.ac.xx	**دورنگار**	+؟؟-؟؟-؟؟؟؟؟؟؟؟

این مقاله در مرحله ویراستاری بوده و نسخه نهایی آن به زودی در سایت مجله قرار داده خواهد شد

۱- مقدمه

بیماری‌های قلبی و عروقی، امروزه به‌عنوان یکی از مهم‌ترین عوامل تهدیدکننده سلامتی انسان‌ها محسوب می‌شوند و ازجمله مهم‌ترین عامل‌های مرگ‌ومیر در جامعه هستند [۱]. بسیاری از بیماری‌ها و ناهنجاری‌های قلبی با استفاده از تکنیک‌های شنیداری، قابل‌تشخیص و ارزیابی می‌باشند به‌طوری‌که حتی در برخی از بیماری‌های مهم قلبی، این تکنیک‌ها همچنان ازجمله روش‌های کارا و قابل‌اعتماد به‌حساب می‌آیند. امروزه در اکثر کشورهای پیشرفته و نیز در کشورهای درحال‌توسعه، محققین درصدد پردازش این صداها و استخراج ویژگی‌های مهم آن‌ها به‌منظور پی بردن به برخی از بیماری‌ها می‌باشند [۲].

سیگنال صدای قلب[۱] (PCG) یک سیگنال غیر ایستان و شبه متناوب می‌باشد. هر چرخه از این سیگنال به چهار بخش مهم با نام‌های سیگنال S_1، قطعه سیستول، سیگنال S_2 و قطعه دیاستول تقسیم می‌شود. در شکل (۱) این بخش‌ها برای یک نمونه سیگنال صدای قلب نشان داده‌شده است. در چند دهه گذشته آنالیز صدای قلب به‌طور گسترده موردمطالعه قرارگرفته است. تحقیقات نشان می‌دهد که تکنیک‌های قطعه‌بندی و طبقه‌بندی خودکار صدای قلب پتانسیل غربالگری مناسبی را در آسیب‌شناسی بالینی قلب با هزینه نسبتاً کم دارند. ازجمله این روش‌ها می‌توان به دسته‌بندی صداهای ناهنجار از صداهای 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، درزمینه‌ی طبقه‌بندی سیگنال‌های صوتی قلب به دو دسته طبیعی و غیرطبیعی، روش‌های مختلفی پیشنهادشده که در آن‌ها از شبکه عصبی [۸]، ماشین بردار پشتیبان [۹, ۱۰] ، شبکه عصبی کانولوشن [۸, ۱۱] برای شناسایی استفاده نموده‌اند.

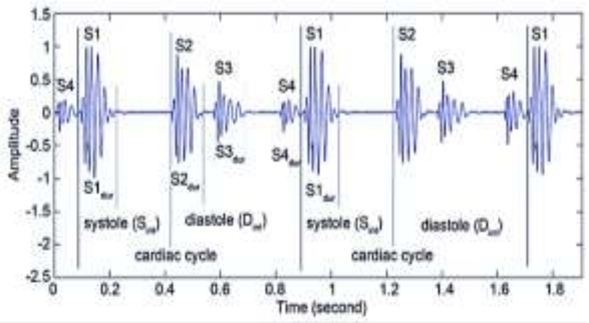

شکل ۱. سیگنال صدای قلب [۱۲].

روش‌های فوق‌الذکر باوجوداینکه از انواع مختلفی از ویژگی‌ها برای طبقه‌بندی صداهای قلبی استفاده می‌کنند، ولی صحت مناسبی را ندارند. در این مقاله به معرفی روشی برای تشخیص صداهای طبیعی از غیرطبیعی قلبی پرداخته می‌شود که دارای صحت، حساسیت و اختصاصیت مناسب‌تری نسبت به سایر روش‌های پیشنهادی حال حاضر در این زمینه می‌باشد. ساختار این مقاله به شرح زیر است:

در بخش دوم، ابتدا به معرفی پایگاه داده‌ی مورداستفاده در این مقاله پرداخته می‌شود. سپس در این بخش به ترتیب، نحوه قطعه‌بندی سیگنال‌های قلبی، ویژگی‌های استخراج‌شده توضیح داده می‌شود. در ادامه این بخش، دو روش پیشنهادی برای انتخاب ویژگی‌ها مبتنی بر جستجوی سلسله مراتبی روبه‌جلو[۳] (SFFS) و الگوریتم بهینه‌سازی ازدحام ذرات[۴] (PSO) معرفی می‌گردند و سپس در مورد طبقه‌بندهای مورداستفاده در این مقاله صحبت خواهد گردید. در انتها در مورد نحوه متوازن‌سازی داده‌ها در این مقاله صحبت خواهد گردید. در بخش سوم نتایج استفاده از روش پیشنهادی بر روی پایگاه داده‌ی چالش فیزیونت ۲۰۱۶ [۱۳] مورد ارزیابی قرار خواهد گرفت و بخش آخر مربوط به نتیجه‌گیری خواهد بود.

۲- مواد و روش‌ها

در این بخش به معرفی روش پیشنهادی برای طبقه‌بندی صداهای طبیعی از غیرطبیعی می‌پردازیم. بلوک دیاگرام روش پیشنهادی در شکل (۲) نشان داده‌شده است و مراحل آن

---

[۱] Phonocardiogram
[2] Mel Cepstral Coefficients
[3] Sequential Forward Feature Selection
[4] Particle Swarm Optimization Algorithm

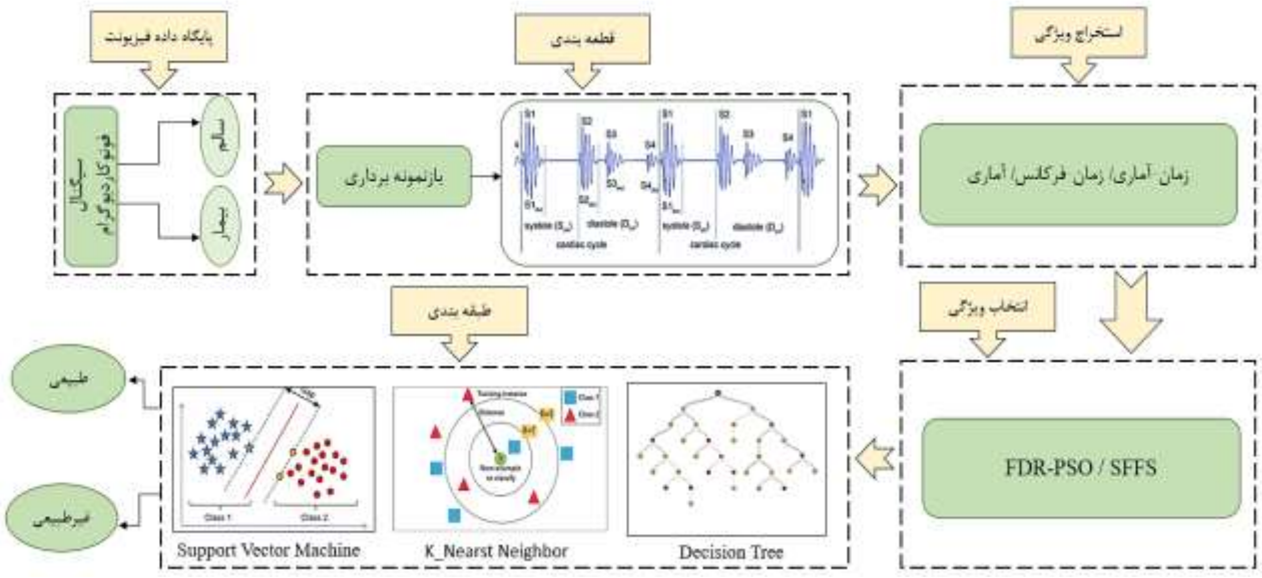

شکل ۲. نمایش بلوکی روش پیشنهادی.

بدین‌صورت است که سیگنال‌های فونوکاردیوگرام ابتدا در فرکانس ۱۰۰۰ هرتز باز نمونه‌برداری می‌شوند. سپس با استفاده از الگوریتم قطعه‌بندی پیشنهادی در [۱۴] به چهار ناحیه مختلف تقسیم می‌شوند. سپس از هرکدام از ناحیه‌ها ویژگی‌های مختلف زمانی آماری، زمانی فرکانسی و آماری استخراج می‌شود. در مرحله بعد از دو رهیافت پیشنهادی جهت انتخاب ویژگی استفاده‌شده است. در رهیافت اول از PSO و نرخ تفکیک‌پذیری فیشر[۵] (FDR) و در رهیافت دوم از SFFS برای انتخاب ویژگی استفاده گردیده است. در مرحله بعدی ویژگی‌های برتر برای طبقه‌بندی به طبقه‌بندهای متداول داده می‌شود.

۲-۱- پایگاه داده

در پژوهش حاضر، از پایگاه داده‌ی چالش ۲۰۱۶ فیزیونت برای ارزیابی روش پیشنهادی استفاده‌شده است. این پایگاه داده به‌طور مستقل با جمع‌آوری بزرگ‌ترین بانک اطلاعاتی صدای قلب عمومی، از هشت منبع توسط هفت گروه به‌دست‌آمده است. این بانک اطلاعاتی شامل ۳۱۵۳ ضبط از ۷۶۴ فرد سالم و بیمار با انواع مختلفی از بیماری‌ها مانند بیماری دریچه قلب، بیماری عروق کرونر می‌باشد که از افراد در سنین مختلف در هر دو محیط بالینی و غیر بالینی جمع‌آوری‌شده است [۱۳]. تمام صداهای ضبط‌شده قلب به دو نوع طبیعی و غیرطبیعی علامت‌گذاری شده‌اند که شامل ۲۴۸۸ صدای ضبط‌شده‌ی طبیعی مربوط به فرد سالم و ۶۶۵ صدای ضبط‌شده غیرطبیعی مربوط به بیمارانی بوده‌اند که با انواع مختلفی از بیماری قلب و عروق مواجه بوده‌اند. همه ضبط‌ها در فرکانس ۲۰۰۰ هرتز نمونه‌برداری شده‌اند. جزئیات بیشتر در مورد پایگاه داده در [۱۵] آمده است.

۲-۲- قطعه‌بندی سیگنال‌های PCG

قطعه‌بندی صداهای اصلی قلب[۶] (FHS)، یک مرحله ضروری در تجزیه‌وتحلیل خودکار فونوکاردیوگرام است[۲]. در این پژوهش، قبل از قطعه‌بندی، سیگنال‌های فونوکاردیوگرام ابتدا به فرکانس ۱۰۰۰ هرتز باز نمونه‌برداری شده‌اند. محلی‌سازی دقیق FHs ها پیش‌نیازی برای شناسایی نواحی سیستولیک و دیاستولیک فونوکاردیوگرام است که امکان طبقه‌بندی بعدی موقعیت‌های پاتولوژی در این مناطق را فراهم می‌کند[۱۶]. FHsها، به صدای اول قلب (S_1) و صدای دوم قلب (S_2) اشاره دارند [۱۷]. ازآنجایی‌که تمرکز این پژوهش بر روی طبقه‌بندی صداهای طبیعی از غیرطبیعی و نه خود فرآیند قطعه‌بندی است، از الگوریتم پیشنهادشده در [۱۴]، برای قطعه‌بندی سیگنال‌های فونوکاردیوگرام استفاده گردیده است. این روش که یکی از روش‌های محبوب در قطعه‌بندی صداهای قلب است توسط سایر مطالعات درزمینه طبقه‌بندی صداهای قلبی نیز استفاده‌شده است. در این روش برای استخراج محل صداهای

---

[۵] Fischer Discrimination Ratio

[۶] Fundamental Heart Sounds

S_1، سیستول، S_2 و دیاستول از مدل نیمه پنهان مارکوف[۷] (HSMM) و رگرسیون لجستیک[۸] (LR) استفاده گردیده است. مدل HSSM فوق با استفاده از داده‌های موجود در پوشه a موجود در پایگاه داده چالش ۲۰۱۶ فیزیونت آموزش‌دیده است. داده‌های موجود در این پوشه، علاوه بر سیگنال صدای قلبی حاوی سیگنال ECG[۹] می‌باشند که به‌صورت هم‌زمان در فرآیند ثبت داده از بیماران ضبط گردیده است. در شکل (۳) عملکرد الگوریتم قطعه‌بندی پیشنهادی در [۱۴] بر روی بخشی از ثبت (a0011) موجود در پایگاه داده چالش فیزیونت ۲۰۱۶ نشان داده‌شده است.

۳-۲- استخراج ویژگی

پس از قطعه‌بندی، از نواحی یافت شده در سیگنال صوتی ویژگی‌های مختلفی برای طبقه‌بندی استخراج می‌گردد. هدف از استخراج ویژگی یافتن فشرده‌ترین و آموزنده‌ترین مجموعه ویژگی‌ها برای افزایش کارایی طبقه‌بند است. اگر ویژگی‌ها به‌درستی انتخاب نشوند ممکن است عملکرد طبقه‌بندی کاهش یابد. ویژگی‌هایی که در این تحقیق استخراج گردید به سه دسته زیر تقسیم می‌گردند:

۱) ویژگی‌های حوزه زمانی _ آماری

۲۸ ویژگی زمانی-آماری مربوط به طول‌های زمانی ۴ ناحیه شاخص موجود در صداهای قلبی استخراج گردید [۱۸]. این ویژگی‌ها مربوط به میانگین و انحراف معیار مدت‌زمان هر چهار ناحیه صدای قلب، میانگین و انحراف معیار نسبت مدت‌زمان ناحیه‌ها نسبت به یکدیگر و میانگین و انحراف معیار نسبت فواصل ناحیه‌ها به طول هر ضربان قلب می‌باشد. کشیدگی‌های طول‌های زمانی نواحی نیز به‌عنوان ویژگی در نظر گرفته شد.

۲) ویژگی‌های حوزه زمانی _ فرکانسی:

۸۲ ویژگی از چگالی‌های طیفی توان[۱۰] (PSD) نواحی قطعه‌بندی شده استخراج گردید. ابتدا تبدیل فوریه گسسته ۱۰۰ نمونه‌ای برای هرکدام از قطعات صداهای قلبی S_1، سیستول، S_2 و دیاستول محاسبه می‌شود و پس از به دست آوردن چگالی طیف توان، در چهار ماتریس جداگانه ذخیره می‌شود. برای ماتریس مربوط به S_1 ستون‌های ۲ تا ۱۳ چگالی طیف توان، برای ماتریس سیستول ستون‌های ۲ تا ۳۰ چگالی طیف توان، برای ماتریس S_2 ستون‌های ۲ تا ۱۳ چگالی طیف توان و برای ماتریس دیاستول ستون‌های ۲ تا ۳۰ چگالی طیف توان انتخاب‌شده و به‌صورت ستونی از ماتریس‌های مربوطه میانگین‌گیری می‌شود. این مقادیر به‌صورت ویژگی‌های استخراج‌شده مورداستفاده قرار می‌گیرد.

۶ ویژگی انرژی نیز از ماتریس‌های فوق‌الذکر استخراج می‌گردد بدین‌صورت که پس از محاسبه 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 محاسبه‌شده و به‌عنوان ویژگی در نظر گرفته می‌شود. درمجموع ۱۱۶ ویژگی از هر صدای قلبی استخراج گردید.

۴-۲- رهیافت‌های پیشنهادی برای انتخاب ویژگی

پس از استخراج ویژگی‌های مختلف، می‌توان از معیارهای مختلفی برای انتخاب ویژگی استفاده نمود. معیارهایی مانند t-test، آنتروپی[۱۱] و باتاچارایا[۱۲] برای انتخاب ویژگی‌هایی که توزیع گوسی دارند و معیارهایی مانند ناحیه همگرایی[۱۳] (RoC) و ویلکاکسون[۱۴] با فرض اینکه ویژگی‌ها توزیع گوسی ندارند، برای انتخاب ویژگی مورداستفاده قرار می‌گیرند. در این بخش ابتدا به معرفی رهیافتی مبتنی بر الگوریتم ازدحام ذرات می‌پردازیم که نرخ تفکیک‌پذیری ویژگی‌ها را طوری افزایش دهد که هنگام استفاده از معیارهای بالا برای انتخاب ویژگی، عملکرد طبقه‌بندها افزایش یابد. بایستی این نکته را خاطر نشان کرد که این مقاله یکی از اولین پژوهش‌ها در زمینه طبقه‌بندی صداهای قلبی است که از الگوریتم‌های فراابتکاری برای بهبود عملکرد طبقه‌بندها استفاده کرده‌است. در ادامه این زیر بخش به معرفی رهیافت دوم انتخاب ویژگی که بر اساس روش SFFS می‌باشد، خواهیم پرداخت.

۱-۴-۲- رهیافت اول؛ انتخاب ویژگی با استفاده از نرخ تفکیک‌پذیری فیشر

[7] Hidden Semi-Markov Models
[8] Logistic Regression
[۹] Electrocardiogram
[۱۰] Power Spectral Density
[۱۱] Entropy
[۱۲] Bhattacharyya
[۱۳] Region of Convergence
[۱۴] Wilcoxon

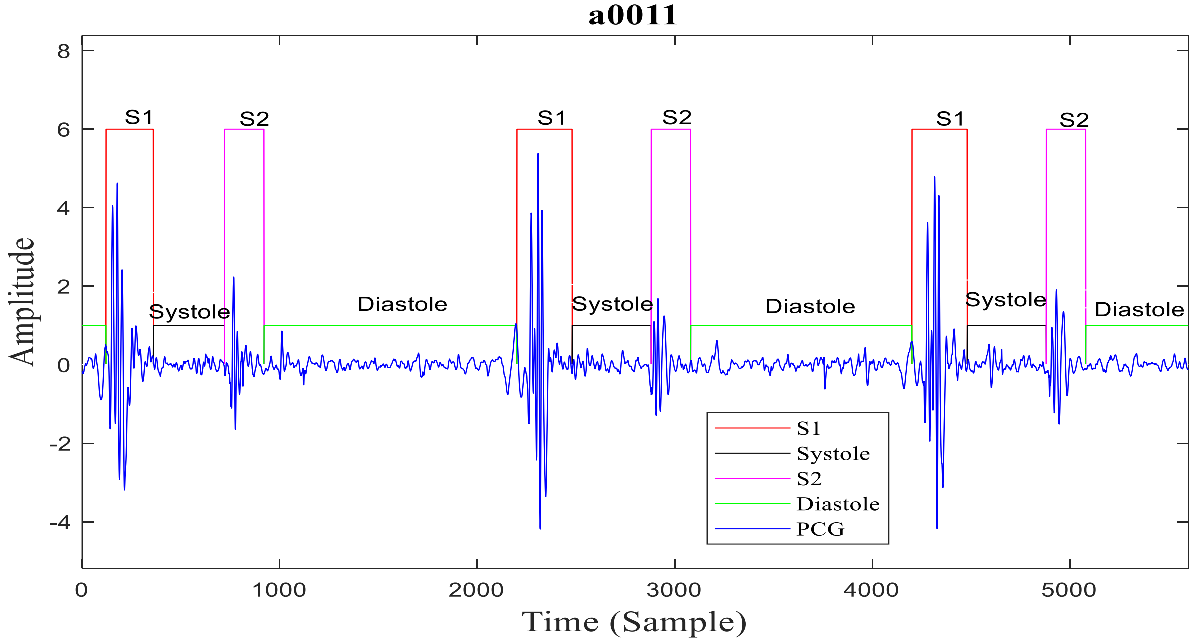

شکل ۳. نتایج قطعه‌بندی سیگنال فونوکاردیوگرام با استفاده از روش HSMM بر روی بخشی از ثبت «a0011» موجود در پایگاه داده چالش فیزیونت ۲۰۱۶.

با فرض اینکه ویژگی‌ها توزیع گوسی دارند، می‌خواهیم ویژگی‌ها را طوری تغییر بدهیم که نرخ تفکیک‌پذیری افزایش یابد. یکی از معیارهایی که نرخ تفکیک‌پذیری را بر اساس میانگین و واریانس محاسبه می‌کند، نرخ تفکیک‌پذیری فیشر (FDR) می‌باشد. این نرخ جهت تعیین مقدار تفکیک‌پذیری کلاس‌ها از همدیگر و همچنین میزان تأثیرگذاری هرکدام از ویژگی‌ها در میزان این تفکیک‌پذیری و همچنین امکان ترکیب ویژگی‌ها برای تفکیک‌پذیری بهتر استفاده می‌شود [۱۹].

در روش فیشر جهت تفکیک بهتر دو کلاس از هم، ناحیه مشترک مابین دو کلاس در تابع چگالی احتمال آن‌ها بایستی تا حد ممکن کوچک باشد و با توجه به مفهوم پارامترهای توابع گوسی، کاملاً واضح است که هر چه قدر اختلاف میانگین کلاس‌ها از هم بیشتر بوده و واریانس داخلی کلاس‌ها کوچک‌تر شود، ناحیه مشترک کوچک‌تر شده و کلاس‌ها تفکیک‌پذیری بهتری خواهند داشت. رابطه فیشر برای داده‌های با ۲ کلاس را می‌توان به‌صورت زیر بیان کرد [۲۰]:

$$FDR = \frac{(\mu_1-\mu_2)^2}{(\sigma_1^2-\sigma_2^2)} \quad (۱)$$

که در آن μ_1 و μ_2 به ترتیب مقدار میانگین نقاط داده در کلاس ۱ و ۲ هستند و σ_1 و σ_2 به ترتیب واریانس‌های ۲ کلاس می‌باشد.

۱-۱-۴-۲- بهبود انتخاب ویژگی با استفاده از الگوریتم بهینه‌سازی ازدحام ذرات

معیار FDR را برای چندین ویژگی را به‌صورت زیر نوشت:

$$FDR = \frac{(\mathbf{a}^{\mathrm{T}} * (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2) * (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)^{\mathrm{T}} * \mathbf{a})}{(\mathbf{a}^{\mathrm{T}} * \sum_1 * \mathbf{a} + \mathbf{a}^{\mathrm{T}} * \sum_2 * \mathbf{a})} \quad (۲)$$

که در آن، $\sum_1$ و $\sum_2$ به ترتیب ماتریس کوواریانس ویژگی‌های کلاس ۱ و ماتریس کوواریانس ویژگی‌های کلاس ۲ می‌باشد. همچنین $\boldsymbol{\mu}_1$ و $\boldsymbol{\mu}_2$ به ترتیب ماتریس میانگین ویژگی‌های کلاس ۱ و کلاس ۲ می‌باشد. در رابطه‌ی بالا بردار **a**، بردار ضرایب اهمیت[۱۵] ویژگی‌هاست که میزان تأثیر 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** از الگوریتم‌های بهینه‌سازی می‌توان استفاده نمود. الگوریتم بهینه‌سازی استفاده‌شده در این مطالعه، الگوریتم بهینه‌سازی ازدحام ذرات می‌باشد.

---
۱۵ Importance Coefficient

الگوریتم بهینه‌سازی ازدحام ذرات (PSO)، یکی از محبوب‌ترین الگوریتم‌های بهینه‌سازی هوشمند است که در حوزه الگوریتم-های مبتنی بر هوش ازدحامی جای می‌گیرد. این الگوریتم توسط جیمز کندی و راسل سی ابرهارت در سال ۱۹۹۵ معرفی گردید[۲۱] و با الهام از رفتار اجتماعی حیواناتی چون ماهی‌ها و پرندگان که در گروه‌های کوچک و بزرگ زندگی

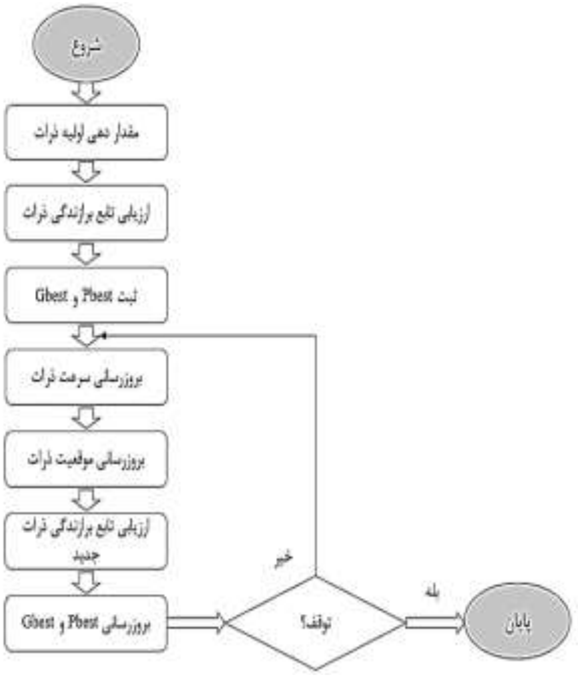

شکل۴. نمایش بلوکی الگوریتم PSO

می‌کنند، طراحی‌شده است. در الگوریتم PSO اعضای جمعیت (جواب‌ها) به‌صورت مستقیم باهم در ارتباط‌اند و از طریق تبادل اطلاعات با یکدیگر و یادآوری جواب‌های خوب گذشته به حل مسائل می‌پردازند. این الگوریتم برای انواع مسائل پیوسته و گسسته مناسب است و پاسخ‌های مناسبی را برای انواع مختلفی از مسائل بهینه‌سازی ارائه داده است. نمایش بلوکی الگوریتم PSO را در شکل (۴) مشاهده می‌کنید. مراحل بهینه‌سازی گام‌به‌گام برای الگوریتم PSO را می‌توان به‌صورت زیر توصیف کرد [۲۲]:

- تنظیم پارامترهای بهینه‌سازی ازدحام ذرات
- ارزیابی تابع برازندگی ذرات
- به‌روزرسانی موقعیت و سرعت ذرات
- برای هر ذره، تابع برازندگی $x_i(t+1)$ با تابع برازندگی $P_{best_i}(t+1)$ مقایسه می‌شوند. اگر مقدار تابع برازندگی این ذره کمتر از مقدار تابع برازندگی $P_{best_i}(t+1)$ باشد آنگاه $x_i(t+1)$ به‌عنوان بهترین تجربه شخصی ذره i ام در مرحله $t+1$ قرار می‌گیرد، در غیر این صورت بهترین تجربه شخصی ذره i ام در مرحله $t+1$ همان بهترین تجربه شخصی ذره i ام در مرحله‌ی t ام است.
- در مرحله $t+1$، بهترین تجربه شخصی ذره‌ای به‌عنوان $G_{best}(t+1)$ انتخاب می‌شود که بهترین تجربه شخصی انتخاب‌شده،
- در بین بهترین تجربه‌های شخصی همه ذرات، کمترین مقدار تابع برازندگی را داشته باشد.
- شرط اتمام الگوریتم بررسی می‌شود. اگر تعداد تکرار الگوریتم به حداکثر تعداد رسیده باشد، به‌عنوان مقدار جواب بهینه یا زیر بهینه اعلام می‌شود و برنامه اتمام می‌شود. در غیر این صورت مرحله دوم شروع می‌شود.

ازنظر ریاضی، موقعیت و سرعت ذرات طبق فرمول ۳ و ۴ زیر به‌روز می‌شوند [۲۳] :

$$x_i(t+1) = x_i(t) + v_i(t+1) \qquad (۳)$$

$$v_i(t+1) = w\,V_i(t) + c_1 R_{1i}[P_{best_i}(t) - X_i(t)] + c_2 R_{2i}[G_{best}(t) - X_i(t)] \qquad (۴)$$

که در آن t تعداد تکرارهای الگوریتم، w معرف وزن اینرسی، $V_i(t)$ جابجایی با توجه به سرعت فعلی ذره، $X_i(t)$ موقعیت ذره، $P_{best_i}(t)$ جابجایی در جهت بهترین عملکرد ذره iام تاکنون، $G_{best}(t)$ جابجایی در جهت بهترین عملکرد اطلاع‌رسانی شده از ذرات دیگر تاکنون، c_1 و c_2 به ترتیب، ضریب یادگیری شناختی و ضریب یادگیری اجتماعی است.R_1 و R_2 دو عدد تصادفی با توزیع یکنواخت در بازه $[0,1]$ هستند.

در هر تکرار الگوریتم، ذره‌ای که بهترین جواب سرتاسری[۱۶] را دارد ثبت‌شده و در تکرار بعدی، الگوریتم با به‌روزرسانی موقعیت ذرات و مقایسه جواب‌ها با بهترین جواب یافت شده ادامه می-یابد تا زمانی که شرط توقف حاصل گردد.

در الگوریتم بهینه‌سازی ازدحام ذرات پیشنهادی، از تابع برازندگی[۱۷] زیر استفاده می‌گردد:

$$FitnessFunction = \frac{1}{FDR} = \frac{(\boldsymbol{a}^{\mathrm{T}} * \sum_1 * \boldsymbol{a} + \boldsymbol{a}^{\mathrm{T}} * \sum_2 * \boldsymbol{a})}{(\boldsymbol{a}^{\mathrm{T}} * (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2) * (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)^{\mathrm{T}} * \boldsymbol{a})} \qquad (۵)$$

---
۱۶ Global Solution

۱۷ Fitness Function

با تعریف تابع برازندگی به‌صورت رابطه بالا، به حداقل رساندن تابع باعث به حداکثر رساندن FDR می‌شود. هدف در اینجا پیدا کردن بهترین مقادیر برای درایه‌های بردار **a** است به قسمی که تابع برازندگی معادله (۵) کمینه گردد.

پس از یافتن مقدار بهینه **a**، این بردار به‌صورت درایه به درایه در ویژگی‌های استخراج‌شده ضرب می‌شود و سپس با استفاده از معیارهای t-test، آنتروپی و باتاچارایا عملیات انتخاب ویژگی انجام می‌پذیرد.

۲-۴-۲- رهیافت دوم؛ انتخاب ویژگی با استفاده از روش جستجوی سلسله مراتبی روبه‌جلو SFFS

روش جستجوی سلسله مراتبی روبه‌جلو (SFFS)، یکی از محبوب‌ترین روش‌های انتخاب ویژگی به‌صورت برداری است [۲۴]. این روش بهترین ترکیب ممکن را از میان ویژگی‌های موجود بر اساس طبقه‌بند موردنظر انتخاب می‌کند به قسمی که باعث افزایش عملکرد آن طبقه‌بند شود. این روش یکی از ساده‌ترین و سریع‌ترین الگوریتم جستجوی حریصانه[۱۸] است 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 به‌صورت مرحله‌به‌مرحله به این بردار اضافه می‌کند تا زمانی که معیار خاتمه برآورده شود [۲۵]. بردار حاصله، یک زیر فضا از کل فضای ویژگی است که به ازای آن عملکرد طبقه‌بند نسبت به حالت اولیه‌ی استفاده از کل ویژگی-ها بهبودیافته است. نحوه انتخاب ویژگی با استفاده از روش SFFS در شکل(۵) نشان داده‌شده است. در این مقاله از روش SFFS بعنوان 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 خواهد شد.

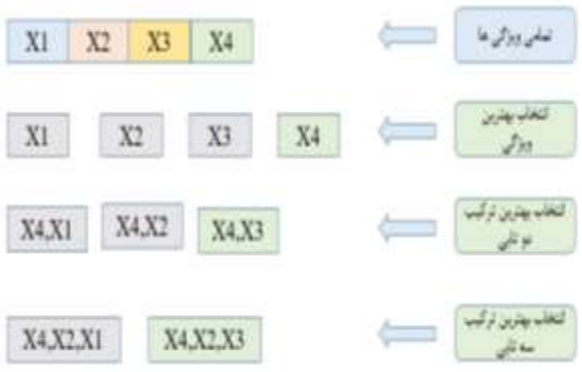

شکل ۵. نحوه انتخاب ویژگی با استفاده از SFFS.

۲-۵- طبقه‌بندی

در این پژوهش، برای طبقه‌بندی صداهای قلب طبیعی و غیرطبیعی از شش طبقه‌بند با نظارت ماشین بردار پشتیبان[۱۹] (SVM)، ماشین بردار پشتیبان با کرنل تابع پایه شعاعی[۲۰] (RBF SVM)، k نزدیک‌ترین همسایه[۲۱] (KNN)، k نزدیک‌ترین همسایه وزن‌دار[۲۲] (WKNN) ، درخت تصمیم[۲۳] (DT) و بیز ساده[۲۴] (NB) استفاده‌شده است که در ادامه به توضیح هرکدام خواهیم پرداخت.

۲-۵-۱- ماشین بردار پشتیبان

ماشین بردار پشتیان (SVM) ، یک مدل یادگیری ماشین با ناظر است که توسط آقای ولادیمیر وپنیک، در سال ۱۹۹۵ برای طبقه‌بندی داده‌های ۲ کلاسه خطی مطرح شد. بعداً این طبقه-بند توسط خود وپنیک برای مسائل غیرخطی و چند کلاسه توسعه پیدا کرد[۲۶]. ماشین بردار پشتیبان با توجه به داده‌های برچسب‌دار آموزشی، یک ابرفضای[۲۵] بهینه را ارائه می‌کند تا داده‌های جدید را به دسته‌های مختلف طبقه‌بندی کند. اساس طبقه‌بندی SVM، طبقه‌بندی خطی داده‌هاست. ماشین بردار پشتیبانی درواقع یک طبقه‌بند دودویی است که دو کلاس را با استفاده از یک مرز خطی با بیشینه‌سازی حاشیه از هم جدا می‌کند که به‌صورت رابطه (۶) بیان می‌شود[۲۷] :

$$y(\mathbf{x}) = \mathbf{w}^T \varphi(\mathbf{x}) + \mathbf{b} \qquad (۶)$$

[۱۸] Greedy Search
[۱۹] Support Vector Machine
[۲۰] Radial Basis Function
[۲۱] K-nearest Neighborhood
[۲۲] Weighted K-nearest Neighborhood
[۲۳] Decision Tree
[۲۴] Naïve Bayes
[۲۵] Hyper Plane

مجله‌ی مهندسی پزشکی زیستی، دوره ۱۶، شماره ۳، پاییز ۱۴۰۱، ۲۷۱ - ۲۸۹

در رابطه‌ی بالا $\mathbf{w}$ بردار وزن، $\mathbf{b}$پارامتر بایاس و φ، تابع هسته است. عملکرد SVM به نوع تابع هسته مورداستفاده در رابطه‌ی (۶) بستگی دارد. برای جداسازی داده‌های غیرخطی، استفاده از توابع هسته‌ی غیرخطی باعث بهبود در عملکرد SVM خواهد شد. یکی از گونه‌های متداول توابع غیرخطی، توابع پایه شعاعی (RBF) می‌باشند. تابع RBF برای دو بردار $\mathbf{x}_i$ و $\mathbf{x}_j$ میزان شباهت یا نزدیک بودن آن‌ها به یکدیگر را محاسبه می‌کند. این هسته را می‌توان به‌صورت ریاضی به‌صورت رابطه (۶) نشان داد:

$$k(x_i.x_j) = \exp(-\sigma\|\mathbf{x}_i - \mathbf{x}_j\|^2) \quad (۷)$$

که در آن، σ میزان واریانس است و به‌عنوان یک فرا پارامتر در نظر گرفته می‌شود و $\|\mathbf{x}_i - \mathbf{x}_j\|^2$ فاصله اقلیدسی بین دو بردار $\mathbf{x}_i$ و $\mathbf{x}_j$ می باشد.

۲-۵-۲- k نزدیک‌ترین همسایگی

طبقه‌بند k نزدیک‌ترین همسایه (KNN) یک روش غیر پارامتریک است که به‌طور گسترده در تجزیه‌وتحلیل سیگنال های زیست پزشکی استفاده‌شده است. در این روش، برای برچسب‌گذاری هر داده، برچسب k عدد از داده‌هایی که نزدیک‌ترین فاصله را از داده دارند بررسی‌شده و پس از پیدا شدن برچسب اکثریت، آن برچسب به داده مزبور داده می‌شود.

در الگوریتم KNN، k نمونه همسایه سهم یکسانی در رأی‌گیری خواهند داشت. این در حالی است که همسایه‌های نزدیک‌تر بایستی سهم بیشتری در مقایسه با همسایه‌های دورتر داشته باشند. ازاین‌رو، الگوریتم دیگری با عنوان الگوریتم k نزدیک‌ترین همسایه وزن‌دار توسعه‌یافته است که در آن طبقه‌بندی بر اساس میزان شباهت همسایه‌های نزدیک به داده آزمایشی انجام می‌شود.

در الگوریتم پیشنهادی، مقدار k=5 در نظر گرفته‌شده است. همچنین برای محاسبه وزن k همسایه انتخاب‌شده، از رابطه (۸) استفاده شده است :

$$W_{\mathbf{x}_i.\mathbf{x}_j} = \frac{1}{d(\mathbf{x_i}.\mathbf{x_j})} \quad (۸)$$

که در آن $d(\mathbf{x_i},\mathbf{x_j})$ فاصله دو بردار $\mathbf{x}_j$ و $\mathbf{x}_i$ از همدیگر می‌باشد.

۳-۵-۲- 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، طبقه رابطه زیر دانش اولیه و دانش اندازه‌گیری شده را به احتمالات پسین تبدیل می‌کند و از آن برای تصمیم‌گیری استفاده می‌کند. به این صورت که داده جدید به کلاسی تعلق دارد که بیشترین احتمال پسین را نسبت به آن کلاس در مقایسه با سایر کلاس‌ها داشته باشد. رابطه (۹)، بیان‌کننده این نوع طبقه‌بند می‌باشد.

$$p(w_j \mid \mathbf{x}) = \frac{p(\mathbf{x} \mid w_j)p(w_j)}{p(\mathbf{x})} \quad (۹)$$

در این رابطه $p(wj)$ دانش اولیه در مورد هر کلاس (احتمال وقوع هر کلاس) است، $p(\mathbf{x} \mid w_j)$ میزان شباهت داده ورودی به هر کلاس را مشخص می‌کند $p(\mathbf{x})$ و ثابت نرمالیزاسیون است [۲۸]. اگر $p(w_j)$ را برای همه کلاس‌ها یکسان در نظر بگیریم، آنگاه به طبقه‌بند فوق، طبقه‌بند بیز ساده می‌گویند.

۴-۵-۲- درخت تصمیم

یکی از پرکاربردترین الگوریتم‌های داده‌کاوی، الگوریتم درخت تصمیم (DT) می‌باشد که از آن می‌توان برای پیش‌بینی و طبقه‌بندی استفاده نمود. درخت تصمیم یک روش رایج برای نشان دادن فرآیند تصمیم‌گیری به‌وسیله ساختاری درخت مانند و شاخه‌دار است. به‌طورکلی درخت تصمیم روشی برای مدل‌سازی تصمیم‌ها، خروجی آن‌ها و همچنین نگاشت تصمیم‌ها در ساختاری درختی است. این الگوریتم روشی برای محاسبه پتانسیل موفقیت دنباله‌های مختلف تصمیم‌گیری در دستیابی به یک هدف خاص به‌حساب می‌آید. درخت تصمیم از گره‌های مختلفی ایجادشده است. گره ریشه[۲۶] محل شروع درخت تصمیم به‌حساب می‌آید که معمولاً تمام مجموعه داده مسئله را شامل می‌شود. گره‌های برگ[۲۷] نقطه پایانی هر شاخه درخت یا خروجی نهایی مجموعه‌ای از تصمیم‌ها هستند. هر شاخه درخت تصمیم در یادگیری ماشین فقط دارای یک گره برگ است.

---

۲۶ Root Node

۲۷ Leaf

در درخت تصمیم برای پیش‌بینی کلاس‌های موردنظر مجموعه داده مسئله، رویکرد الگوریتم از گره ریشه درخت آغاز می‌شود. این الگوریتم، مقادیر ویژگی‌های ریشه را با ویژگی‌های داده‌ها مقایسه و بر اساس این مقایسه، شاخه‌ها را دنبال می‌کند و به گره بعدی می‌رود. برای گره بعدی، الگوریتم دوباره مقدار ویژگی داده‌ها را با زیر گره‌های دیگر مقایسه می‌کند و روند ایجاد درخت را پیش می‌برد. این رویکرد تا رسیدن به گره برگ یا گره انتهایی درخت ادامه پیدا می‌کند.

۶-۲- متوازن‌سازی داده‌ها

به دلیل اینکه تعداد ضبط‌های طبیعی با ضبط‌های غیرطبیعی در پایگاه داده مورداستفاده در این پژوهش برابری نمی‌کند، پس از استخراج ویژگی، ما از الگوریتم بیش نمونه‌برداری اقلیت مصنوعی[۲] (SMOTE) استفاده کردیم تا پایگاه داده را متعادل کنیم. در این روش نمونه‌های کلاس اقلیت با ایجاد نمونه‌های مصنوعی افزایش می‌یابد. این نمونه‌های مصنوعی با استفاده از نمونه‌های واقعی کلاس اقلیت تولید می‌شوند.

در روش SMOTE نمونه‌های مصنوعی در چند گام تولید می‌شوند. در گام نخست یک بردار ویژگی از کلاس اقلیت انتخاب می‌گردد و k نزدیک‌ترین همسایه‌ی آن انتخاب می‌شود. برای هر همسایه، اختلاف بین بردار ویژگی موردنظر و آن همسایه محاسبه‌شده و در یک عدد تصادفی بین یک و صفر ضرب خواهد شد. سپس مقدار حاصل‌شده به بردار ویژگی موردنظر اضافه می‌شود. این کار باعث انتخاب یک نقطه 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 همه نمونه‌های مصنوعی موردنیاز تولید شوند [۲۹]. بعد از اعمال الگوریتم SMOTE، تعداد داده‌ها به ۵۱۰۴ بردار ویژگی افزایش پیدا کرد که شامل ۲۵۰۰ نمونه طبیعی و ۲۶۰۴ نمونه غیرطبیعی بود.

۳- ارزیابی نتایج الگوریتم پیشنهادی

در این مطالعه برای ارزیابی عملکرد طبقه‌بندها در الگوریتم پیشنهادی، از ارزیابی متقابل k لایه[۲۸] (K=10)، استفاده گردید. روند کار ارزیابی متقابل بدین‌صورت است که ۹۰ درصد داده‌ها به‌عنوان داده‌های آموزشی و ۱۰ درصد داده‌ها به‌عنوان داده‌های آزمایش به کار گرفته‌شده‌اند، این روند کار در ۱۰ مرحله تکرار، انجام می‌گیرد و همه داده‌ها هم در گروه آزمایش و هم در گروه آموزش استفاده می‌شوند و در نهایت متوسط نتایج ۱۰ بار تکرار به‌عنوان تخمین نهایی استفاده می‌شوند.

۱-۳- معیارهای ارزیابی عملکرد

تاکنون از روش‌های زیادی برای ارزیابی عملکرد طبقه‌بندها استفاده‌شده است. یکی از بهترین این روش‌ها، محاسبه ماتریس درهم‌ریختگی[۲۹] بر روی مجموعه داده‌های آزمایشی و محاسبه شاخص‌های دقت، حساسیت و اختصاصیت از ماتریس درهم‌ریختگی برای ارزیابی نتایج طبقه‌بندی می‌باشد. یک ماتریس درهم‌ریختگی برای طبقه‌بندی دو کلاسه به‌صورت رابطه زیر بیان می‌گردد:

$$\text{Confusion Matrix} = \begin{bmatrix} TP & FN \\ FP & TN \end{bmatrix} \qquad (۱۰)$$

علائم به‌کاررفته در ماتریس بالا به‌صورت زیر تعریف می‌شوند:

TP: بیانگر مثبت واقعی[۳۰] یا تعداد نمونه‌هایی است که به‌درستی بیمار تشخیص داده‌شده‌اند.

TN: بیانگر منفی واقعی[۳۱] یا تعداد نمونه‌هایی است که به‌درستی سالم تشخیص داده‌شده‌اند.

FP: بیانگر مثبت کاذب[۳۲] یا تعداد نمونه‌هایی است که به‌اشتباه بیمار تشخیص داده‌شده‌اند.

FN: بیانگر منفی کاذب[۳۳] یا تعداد نمونه‌هایی است که به‌اشتباه سالم تشخیص داده‌شده‌اند.

شاخص‌های حساسیت[۳۴] (Sen)، اختصاصیت[۳۵](Spe) و صحت[۳۶] (Acc) به‌صورت زیر تعریف می‌گردند:

---

[۲۸] K-fold Cross Validation
[۲۹] Confusion Matrix
[۳۰] True Positive
[۳۱] True Negative
[۳۲] False Positive
[۳۳] False Negative
[۳۴] Sensitivity
[۳۵] Specificity
[۳۶] Accuracy

این مقاله در مرحله ویراستاری بوده و نسخه نهایی آن به زودی در سایت مجله قرار داده خواهد شد

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

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

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

۲-۳- نتایج

در ادامه، نتایج ارزیابی روش پیشنهادی مبتنی بر رهیافت اول و رهیافت دوم توضیح داده می‌شود.

۱-۲-۳- نتایج رهیافت اول

قبل از ارائه نتایج مربوط به رهیافت اول، ابتدا ۱۱۶ ویژگی توسط طبقه‌بندهای مختلف ارزیابی شد. در جدول (۱) نتایج حاصله به ازای طبقه‌بندهای مختلف نشان داده‌شده است. همان‌طور که در جدول (۱) نشان داده‌شده است، طبقه‌بند RBF SVM توانسته به نتایج بالاتری نسبت به سایر طبقه‌بندها برسد. در مرحله بعدی برای بهبود نتایج جدول (۱) از معیارهای مختلف انتخاب ویژگی مانند t test، آنتروپی و باتاچارایا با فرض

جدول ۱. نتایج حاصل‌شده از رهیافت اول (۱۱۶ویژگی).

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

اینکه ویژگی‌ها توزیع گوسی دارند استفاده گردید. همچنین با معیارهایی مانند RoC و ویلکاکسون با فرض اینکه ویژگی‌ها توزیع گوسی ندارند، نتایج طبقه‌بندها بار دیگر نیز مورد بررسی قرار گرفت. در مرحله بعدی، برای بهبود نتایج مرحله‌ی قبل، با فرض اینکه ویژگی‌ها توزیع گوسی دارند، از انتخاب ویژگی مبتنی بر FDR و PSO استفاده شد. در شکل (۶)، مقادیر درایه‌های بردار **a** برای ۱۱۶ ویژگی استخراج‌شده نمایش داده‌شده است. برای نمایش بهتر، این ضرایب به‌صورت نرمالیزه شده در شکل (۶) نشان داده‌شده است. در جداول ۲ ،۳ و ۴ تأثیر استفاده از رهیافت اول در بهبود عملکرد طبقه‌بندها مشاهده می‌گردد. به‌عنوان‌مثال، در جدول (۲) مشاهده می‌شود، که با استفاده از معیار انتخاب ویژگیt-test و پس از اعمال الگوریتم پیشنهادی مبتنی بر PSO و FDR، طبقه‌بند RBF SVM با ۱۱۴ ویژگی توانسته است به صحت ۹۵/۵۴٪، حساسیت ۹۳/۱۰٪ و اختصاصیت ۹۷/۸۷٪ دست بیابد که نسبت به سایر طبقه‌بندها از نتایج بالاتری برخوردار است. در جدول ۳ نیز مشاهده می‌گردد که عملکرد طبقه‌بندهای KNN و KNN وزن‌دار با اعمال الگوریتم رهیافت اول بهبود یافته‌است. در جدول ۴ نیز با استفاده از رهیافت اول عملکرد طبقه‌بندهای DT و NB بهبود یافته است. با نگاهی به نتایج موجود در جداول ۲، ۳ و ۴ متوجه می‌شویم که بهترین نتایج با استفاده از اعمال رهیافت اول به طبقه‌بند RBF_SVM با استفاده از معیار انتخاب ویژگی t-test می‌باشد. طبقه‌بند مذکور به عنوان روش پیشنهادی اول در جدول ۶ با سایر الگوریتم‌های مراجع مقایسه شده‌است.

۲-۲-۳- نتایج حاصل از رهیافت دوم

در رهیافت دوم روش پیشنهادی، ویژگی‌های استخراج‌شده با استفاده از طبقه‌بندهای SVM، RBF SVM، KNN، WKNN ، DT و NB با کمک روش انتخاب ویژگی SFFS مدل شده‌اند. نتایج حاصل از این رهیافت به‌طور جداگانه در جدول (۵) بیان‌شده است. همان‌طور که در جدول (۵) نشان داده‌شده است RBF SVM با ترکیب ۶۶ ویژگی به صحت ۹۸/۰۳، حساسیت ۹۷/۶۴ و اختصاصیت ۹۸/۴۳ درصد دست‌یافت. طبقه‌بند مذکور به عنوان روش پیشنهادی دوم در جدول ۶ با سایر الگوریتم‌های مراجع مقایسه گردیده‌است.

این مقاله در مرحله ویراستاری بوده و نسخه نهایی آن به زودی در سایت مجله قرار داده خواهد شد

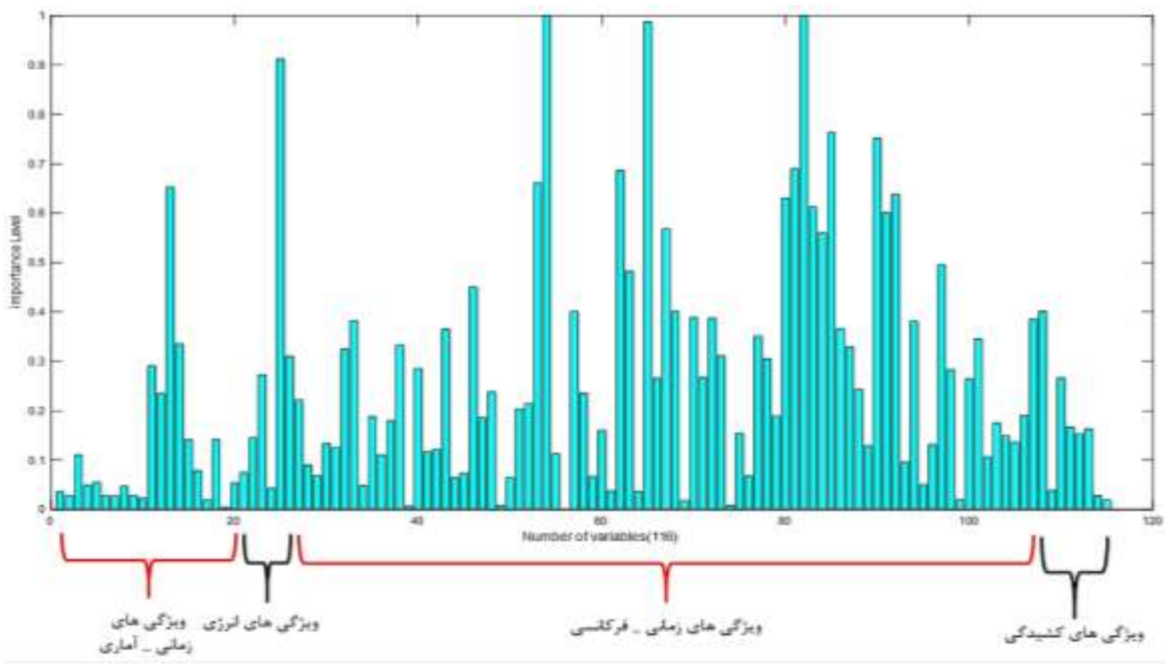

شکل ۶. مقادیر نرمالیزه شده ضرایب a.

۳-۳- مقایسه الگوریتم‌های پیشنهادی با سایر الگوریتم‌های مراجع

در ادامه، عملکرد الگوریتم ارائه‌شده در این مقاله با عملکرد بهترین روش‌های ارائه‌شده در چالش ۲۰۱۶ فیزیونت (که بالاترین امتیازها را کسب کرده بودند)، و همچنین سایر روش های ارائه‌شده در مقالات معتبر که از این پایگاه داده استفاده کرده‌اند، مقایسه شد. نتایج گزارش‌شده در جدول (۶) حاکی از عملکرد بهتر روش پیشنهادی در هر دو رهیافت در مقایسه با بهترین روش‌های موجود است. با وجود اینکه نتایج رهیافت اول نسبت به رهیافت دوم مبتنی بر SFFS کمی ضعیفتر است، اما بازهم نتایج بهتری را نسبت به سایر روشهای موجود در مقالات دیگر در زمینه طبقه بندی صداهای طبیعی قلبی از صداهای غیرطبیعی ارائه داده است.

۳-۴- نتیجه‌گیری

هدف از این مطالعه، ارائه یک روش جدید برای طبقه‌بندی صداهای قلبی به کلاس‌های طبیعی و غیرطبیعی است. برای این منظور ویژگی‌های استخراج‌شده ابتدا با طبقه‌بندهای مختلف مورد ارزیابی قرار گرفت. سپس در مرحله انتخاب ویژگی برای بهبود نتایج از ترکیب الگوریتم FDR-PSO استفاده شد. با به کار بردن الگوریتم FDR-PSO همه نتایج طبقه‌بندهای مختلف بهبود یافت. بالاترین نتایج رهیافت اول مربوط به RBF SVM بود. در رهیافت پیشنهادی دوم، برای رسیدن به نتایج مؤثر طبقه‌بندی، از انتخاب ویژگی SFFS با طبقه‌بندهای SVM، RBF SVM، WKNN، NB و DT استفاده شد و در نهایت با استفاده از معیارهای ارزیابی، الگوریتم پیشنهادی مورد ارزیابی قرار گرفت.

در این مقاله توانستیم با تعداد ویژگی‌های محدود (۱۱۴ ویژگی در رهیافت اول و ۶۶ ویژگی در رهیافت دوم)، داده‌های موجود در پایگاه فیزونت را به خوبی طبقه‌بندی کنیم. نتایج به‌دست‌آمده از ارزیابی‌ها نشان داد که در رهیافت اول با معیار t_test، RBF SVM توانست بهترین نتایج (صحت٪۹۵/۵۴، حساسیت٪۹۳/۱۰ و اختصاصیت ٪۹۷/۸۷) دست یابد. در رهیافت دوم نیز طبقه‌بند روش RBF SVM در مقایسه با سایر روش‌ها توانست با ترکیب۶۶ ویژگی به صحت ٪۹۸/۰۳، حساسیت ٪۹۷/۶۴ و اختصاصیت ٪۹۸/۴۳ برسد. همچنین در

این مقاله در مرحله ویراستاری بوده و نسخه نهایی آن به زودی در سایت مجله قرار داده خواهد شد

جدول ۲. نتایج حاصل از اعمال الگوریتم رهیافت اول برای بهبود عملکرد طبقه‌بندهای SVM و SVM-RBF.

روش‌ها	معیارهای ارزیابی	روش‌های مختلف رتبه‌بندی ویژگی‌ها				
		Wilcoxon	roc	Bhattacharyya	entropy	t-test
SVM	صحت (٪)	۸۶/۸۶	۸۶/۹۴	۸۶/۶۴	۸۶/۶۸	۸۶/۶۴
	حساسیت (٪)	۸۲/۷۰	۸۲/۳۸	۸۲/۳۸	۸۲/۴۰	۸۲/۳۸
	اختصاصیت (٪)	۹۰/۴۸	۹۰/۸۴	۹۰/۷۵	۹۰/۸۳	۹۰/۷۵
PSO_SVM	صحت (٪)	۸۹/۷۲	۸۶/۹۴	۸۶/۸۲	۸۶/۸۴	۸۶/۷۰
	حساسیت (٪)	۸۳/۱۳	۸۲/۸۸	۸۳/۰۳	۸۲/۸۸	۸۲/۸۵
	اختصاصیت (٪)	۹۰/۲۰	۹۰/۸۴	۹۰/۴۷	۹۰/۶۷	۹۰/۶۵
SVM_RBF	صحت (٪)	۹۵/۲۷	۹۵/۳۵	۹۵/۳۵	۹۵/۳۵	۹۵/۵۰
	حساسیت (٪)	۹۲/۶۶	۹۲/۸۲	۹۲/۶۹	۹۲/۶۲	۹۲/۹۳
	اختصاصیت (٪)	۹۷/۷۶	۹۷/۷۵	۹۷/۸۷	۹۷/۹۵	۹۷/۹۴
PSO_SVM_RBF	صحت (٪)	۹۵/۴۷	۹۵/۴۳	۹۵/۴۳	۹۵/۴۱	۹۵/۵۴
	حساسیت (٪)	۹۲/۷۸	۹۲/۸۷	۹۲/۷۹	۹۲/۶۲	۹۳/۱۰
	اختصاصیت (٪)	۹۸/۰۲	۹۷/۸۷	۹۷/۹۵	۹۸/۰۶	۹۷/۸۷

جدول ۳. نتایج حاصل از اعمال الگوریتم رهیافت اول برای بهبود عملکرد طبقه‌بندهای KNN و KNN وزن دار.

این مقاله در مرحله ویراستاری بوده و نسخه نهایی آن به زودی در سایت مجله قرار داده خواهد شد

روش‌ها	معیارهای ارزیابی	روش‌های مختلف رتبه‌بندی ویژگی‌ها				
		t-test	entropy	Bhattacharyya	roc	Wilcoxon
KNN	صحت (٪)	۹۲/۰۹	۹۱/۸۰	۹۲/۰۱	۹۱/۶۰	۹۱/۹۴
	حساسیت (٪)	۸۳/۹۷	۸۳/۳۳	۸۳/۸۰	۸۲/۹۸	۸۳/۶۵
	اختصاصیت (٪)	۹۹/۸۸	۹۹/۹۲	۹۹/۸۸	۹۹/۸۸	۹۹/۸۴
PSO_KNN	صحت (٪)	۹۲/۱۱	۹۱/۸۴	۹۲/۱۱	۹۱/۸۸	۹۲/۰۷
	حساسیت (٪)	۸۴/۰۱	۸۳/۴۷	۸۴/۰۱	۸۳/۵۴	۸۳/۸۴
	اختصاصیت (٪)	۹۹/۸۸	۹۹/۸۴	۹۹/۸۸	۹۹/۸۸	۹۹/۹۶
KNN_Weighted	صحت (٪)	۹۲/۱۱	۹۱/۸۰	۹۲/۰۵	۹۱/۸۸	۹۲/۰۵
	حساسیت (٪)	۸۴/۰۱	۸۳/۳۷	۸۳/۸۸	۸۳/۵۴	۸۳/۸۵
	اختصاصیت (٪)	۹۹/۸۸	۹۹/۸۸	۹۹/۸۸	۹۹/۸۸	۹۹/۹۲
PSO_ KNN_Weighted	صحت (٪)	۹۲/۱۱	۹۲/۱۱	۹۲/۱۱	۹۲/۱۱	۹۲/۱۱
	حساسیت (٪)	۸۴/۰۱	۸۴/۰۱	۸۴/۰۱	۸۴/۰۱	۸۴/۰۱
	اختصاصیت (٪)	۹۹/۸۸	۹۹/۸۸	۹۹/۸۸	۹۹/۸۸	۹۹/۸۸

جدول ۴. نتایج حاصل از اعمال الگوریتم رهیافت اول برای بهبود عملکرد طبقه‌بندهای DT و NB.

روش‌ها	معیارهای ارزیابی	روش‌های مختلف رتبه‌بندی ویژگی‌ها				
		t-test	entropy	Bhattacharyya	roc	Wilcoxon

این مقاله در مرحله ویراستاری بوده و نسخه نهایی آن به زودی در سایت مجله قرار داده خواهد شد

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 (٪)	

جدول ۵ . نتایج حاصل‌شده از رهیافت دوم.

ترکیب ویژگی‌ها	اختصاصیت (٪)	حساسیت (٪)	صحت (٪)	طبقه‌بند
۷۲	۹۱/۷۶	۸۷/۰۵	۸۹/۴۱	SFFS_SVM
۶۶	۹۸/۴۳	۹۷/۶۴	۸۹/۰۳	SFFS_SVM_RBF
۳۷	۱۰۰	۹۱/۳۷	۹۵/۶۸	SFFS_KNN
۲۱	۱۰۰	۹۰/۹۸	۹۵/۴۹	SFFS_KNN_WEIGHTED
۳۷	۸۰/۷۸	۸۶/۶۶	۸۳/۷۲	SFFS_BAYES
به‌طور یکنواخت	۶۷/۸۵	۵۸/۴۳	۷۰/۹۸	SFFS_DT

جدول ۶. مقایسه نتایج نهایی روش‌های پیشنهادی و بهترین روش‌های ارائه‌شده در چالش ۲۰۱۶ فیزیونت.

این مقاله در مرحله ویراستاری بوده و نسخه نهایی آن به زودی در سایت مجله قرار داده خواهد شد

رهیافت دوم طبقه‌بندهای KNN و WKNN توانستند به اختصاصیت ۱۰۰٪ برسد.طبق نتایج به‌دست‌آمده ازلحاظ صحت، حساسیت و اختصاصیت مشاهده شد که الگوریتم پیشنهادی رهیافت دوم با استفاده از طبقه‌بند RBF SVM در

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

مقایسه با سایر روش‌ها به نتایج بالایی دست‌یافته است.

مراجع

[۱] 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

[۲] A. K. Abbas and R. Bassam, "Phonocardiography signal processing," *Synthesis Lectures on Biomedical .Engineering*, vol. 4, no. 1, pp. 1-194, 2009

[۳] 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

[٤] 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

[٥] 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

[٦] 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

[٧] 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 .۲۰۲۱

[٨] Y. Chen, S. Wei, and Y. Zhang, "Classification of heart sounds based on the combination of the modified frequency wavelet transform and convolutional neural network," *Medical & Biological Engineering & Computing*, vol. 58, .۲۰۲۰ ,no. 9, pp. 2039-2047

[٩] 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

[١٠] 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

[١١] 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

[١٢] M. Nabih-Ali, E.-S. A. El-Dahshan, and A. S. Yahia, "Heart diseases diagnosis using

این مقاله در مرحله ویراستاری بوده و نسخه نهایی آن به زودی در سایت مجله قرار داده خواهد شد

intelligent algorithm based on PCG signal analysis," *International Journal of Biology and .Biomedicine*, vol. 2, 2017

[۱۳] 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

[۱٤] Springer, L. Tarassenko, and G. D. .D. B Clifford, "Logistic regression-HSMM-based heart sound segmentation," *IEEE transactions on biomedical engineering*, vol. 63, no. 4, pp. .822-832, 2015

[۱٥] C. Liu *et al.*, "An open access database for the evaluation of heart sound algorithms," *Physiological Measurement*, vol. 37, no. 12, p. .2181, 2016

[۱٦] A. Leatham, *Auscultation of the Heart and .Phonocardiography*. Churchill London, 1970

[۱٧] J. A. Innes, A. R. Dover, and K. Fairhurst, *Macleod's clinical examination*. Elsevier .Health Sciences, 2018

[۱٨] M. N. Homsi *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

[۱٩] H. Li, "A feature S. Wang, D. Li, Y. Wei, and 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

[۲۰] 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," *Innovaciencia Facultad de Ciencias Exactas Físicas y Naturales*, vol. 8, .no. 1, pp. 1-9, 2020

[۲۱] Y. Shi, "Particle swarm optimization," *IEEE .connections*, vol. 2, no. 1, pp. 8-13, 2004

[۲۲] P. Umapathy, C. Venkataseshaiah, and M. S. Arumugam, "Particle swarm optimization with various inertia weight variants for optimal power flow solution," *Discrete Dynamics in .and Society*, vol. 2010, 2010 *Nature*

[۲۳] 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

[۲٤] 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

[۲٥] B. Ashok and P. Aruna, "Comparison of Feature selection methods for diagnosis of cancer using SVM classifier," *Int. J.* cervical .*Eng. Res. Appl*, vol. 6, pp. 94-99, 2016

[۲٦] L. Wang, *Support vector machines: theory and applications*. Springer Science & Business .Media, 2005

[۲٧] C. M. Bishop and N. M. Nasrabadi, *Pattern learning* (no. 4). *recognition and machine* .Springer, 2006

[۲٨] N. Dey, A. S. Ashour, F. Shi, and V. E. Balas, *Soft Computing Based Medical Image .Analysis*. Academic Press, 2018

[۲٩] 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

[۳۰] C. Potes, S. Parvaneh, A. Rahman, and B. Conroy, "Ensemble of feature-based and deep learning-based classifiers for detection of *computing in* ١٦abnormal heart sounds," in *20 cardiology conference (CinC)*, 2016: IEEE, .pp. 621-624

[۳۱] 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

[۳۲] 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