

## **Adaptive Detection of Defects in the Ventricular Heart Disease: A Model with the Possibility of Automatic Analysis of Audio Signals through the Heart**

A. Rezaee<sup>1\*</sup>, S. belbasi<sup>2</sup>

<sup>1</sup>Assistant Professor, System and Mechatronic Group, Faculty of New Sciences and Technologies, University of Tehran, Tehran, Iran

<sup>2</sup>M.Sc. Student, Biomedical Engineering, Islamic Azad University, Tabriz, Iran

Receipt in the online submission system: 8 April 2017, received in revised form: 30 June 2017, accepted: 15 July 2017

---

### **Abstract**

In this paper, a hybrid algorithm has been developed by analyzing the audio signals of the heart, that consists of extracting features based on chaos technique, reducing dimensions and analyzing the main components and classifying outputs by relying on comparative neuro-fuzzy networks. Uncertainty and high error in the diagnosis of inter-ventricular openings are one of the common problems with the previous methods. Due to the importance of the auto-diagnosis of this heart condition, it is necessary to be well-designed and far from error. Transmission of feature spaces to their mapping by the main component analysis algorithm is made by two steps, selecting the number of 18 to 25 attributes among about 50 extracted attributes that these informations are input of the class. The proposed classification classifies the adaptive fuzzy neural network system with the possibility of predicting the incidence of heart disease, which predicts the number of repetitions at the acceptable level of outputs by entering the data. The data are from the Umich database at the University of Michigan and include samples from the ventricular aperture. The ratio of data split in the learning and testing phase is from 0.9 to 0.1 (cross-check), and the K-fold validation method is used. Calculation of criteria such as accuracy, sensitivity and uncertainty by the concept of entropy in a hybrid algorithm suggests the proper performance of the proposed method.

**Key words:** *Disease between ventricular aperture, automatic detection, chaos characteristics, principal component analysis and adaptive fuzzy neural network system.*

---

### **\*Corresponding author**

**Address:** System and Mechatronic Group, Faculty of New Sciences and Technologies, University of Tehran, P.O. Box: 1439957131, Tehran, Iran  
**Tel:** +98-21-86093193  
**Fax:** +98-21-88497324  
**E-mail:** [arrezae@ut.ac.ir](mailto:arrezae@ut.ac.ir)

## تشخیص وفقی وقوع بیماری نقص بین بطنی قلب: مدلی خودکار با امکان آنالیز از طریق سیگنال‌های صوتی قلب

علیرضا رضائی<sup>۱\*</sup>، سارا بلباسی<sup>۲</sup>

<sup>۱</sup>استادیار، گروه مهندسی سیستم و مکترونیک، دانشکده علوم و فنون نوین، دانشگاه تهران، تهران  
<sup>۲</sup>دانشجوی کارشناسی ارشد، گروه بیوالکتریک، دانشکده مهندسی پزشکی، دانشگاه آزاد تبریز، تبریز

تاریخ ثبت در سامانه: ۱۳۹۶/۱/۱۹، بازنگری: ۱۳۹۶/۴/۹، پذیرش قطعی: ۱۳۹۶/۴/۲۴

### چکیده

در مقاله حال حاضر، با آنالیز سیگنال‌های صوتی قلب به طراحی الگوریتمی ترکیبی پرداخته شده که متشکل از استخراج ویژگی بر اساس تکنیک آشوب، کاهش ابعاد توسط آنالیز اجزای اصلی و دسته بندی خروجی‌ها با اتکاء بر شبکه‌های عصبی-فازی تطبیقی می-باشد. عدم قطعیت و خطای بالا در تشخیص روزنه بین بطنی از عدیده مشکلات روش‌های پیشین است که در این زمینه مطرح بوده و به سبب اهمیت تشخیص خودکار این عارضه قلبی، نیاز است تا طراحی وفقی و به دور از بروز خطا باشد. انتقال فضای ویژگی‌ها با نگاشت آنها توسط الگوریتم آنالیز اجزای اصلی در دو گام، با انتخاب تعداد ۱۸ تا ۲۵ ویژگی از میان حدود ۵۰ ویژگی استخراج شده، ورودی طبقه‌بندی پیشنهادی را می‌سازد. طبقه بند پیشنهادی، سیستم شبکه عصبی فازی تطبیقی با امکان پیش‌بینی بروز بیماری قلبی است که با ورود داده‌ها، در تعداد تکرارهای محدود در سطح قابل قبولی خروجی‌ها را پیش‌بینی می‌نماید. داده‌ها از پایگاه داده *Umich* دانشگاه میشیگان دریافت شده و شامل نمونه‌های از بیماری روزنه بین بطنی است. نسبت تقسیم داده‌ها در مرحله یادگیری و آزمایش، ۰/۹ به ۰/۱ (ارزیابی مقاطع) است و از شیوه اعتبارسنجی *K-fold* استفاده شده است. محاسبه معیارهایی چون دقت، حساسیت و نیز عدم قطعیت توسط مفهوم آنتروپی در الگوریتم ترکیبی حاکی از عملکرد مناسب روش پیشنهادی است.

کلیدواژه‌ها: بیماری روزنه بین بطنی، تشخیص خودکار، ویژگی‌های آشوب، آنالیز اجزای اصلی و سیستم‌شبکه‌عصبی‌فازی تطبیقی.

\*نویسنده مسئول

نشانی: گروه فناوری بین رشته ای، بخش مهندسی سیستم و مکترونیک، دانشکده علوم و فنون نوین، دانشگاه تهران، تهران، ایران، کد پستی: ۱۴۳۹۹۵۷۱۳۱

تلفن: ۸۶۰۹۳۱۹۳ (۲۱) ۰۹۸+

دورنگار: ۸۸۴۹۷۳۲۴ (۲۱) ۰۹۸+

پست الکترونیکی: arzeae@ut.ac.ir

## ۱- مقدمه

بیماری روزنه بین بطنی یا نقص دیواره بین بطنی<sup>۱</sup> یکی از انواع بیماری‌های قلبی است که در میان نوزادان شایع می‌باشد [۱]. این بیماری عبارتست از وجود یک سوراخ در دیواره دو حفره پایین قلب موسوم به بطن‌ها که ۲۰٪ بیماری‌های مادرزادی را تشکیل می‌دهند. آمارها حاکی از آن است که در هر ۱۰۰۰ نوزاد متولد شده ۵ نوزاد مبتلا به روزنه بین بطنی هستند [۲]. مشکل از جایی شروع می‌شود که در زمان شکل‌گیری قلب این افراد در زمان جنینی در طول آخرین مرحله از تشکیل بافت قلب یک روزنه در داخل دیواره بین بطن‌ها به وجود می‌آید. در طی مراحل نهایی شکل‌گیری بافت قلبی، این روزنه در نوزادان سالم مسدود می‌شود؛ اما در برخی نوزادان انسدادی وجود ندارد و یا انسداد ناقص است. بنابراین انسداد ناقص این حفره باز منجر به یک بیماری روزنه بین بطنی ابتدایی می‌گردد [۳]. در سراسر دنیا، بیماری‌ها و امراض قلبی-عروقی به عنوان یکی از دلایل عمده در افزایش میزان مرگ و میر شناخته می‌شوند. سازمان بهداشت جهانی<sup>۲</sup> در سال ۲۰۰۵ آماري را منتشر نمود که در آن تخمین زده شده بود سالانه جمعیتی بالغ بر ۱۷/۵ میلیون نفر در سراسر دنیا بر اثر بیماری‌های قلبی و عروقی جان خود را از دست می‌دهند. این رقم، ۳۰٪ کل مرگ و میرهای دنیا را به خود اختصاص داده است [۴]. از میان این میزان مرگ و میر، تخمین زده می‌شود که ۷/۲ میلیون نفر بر اثر انسداد شرایین قلب و ۵/۲ میلیون نفر بر اثر سگته‌های قلبی جان خود را از دست می‌دهند. پیش‌بینی‌های آماری نشان می‌دهند که در سال ۲۰۳۰ در حدود ۲۳/۶ میلیون نفر بر اثر امراض قلبی جان خود را از دست خواهند داد [۵]. گوش دادن به صدای قلب و تحلیل صحیح عملکرد آن از مهارت‌های بسیار سخت محسوب می‌شود که فرد تنها در صورت داشتن تجربه چند ساله قادر خواهد بود با استفاده از آن صداهای طبیعی و غیر طبیعی را از یکدیگر متمایز سازد. دلیل اصلی این مسئله از آنجا نشأت می‌گیرد که صداهای مربوط به عملکرد قلب و صداهای تنفس در ریه‌ها دارای طول بازه زمانی کوتاه هستند و از این رو در یک بازه زمانی کوتاه چندین صدای متفاوت از ناحیه قفسه سینه به گوش خواهد رسید. آنگونه که مشخص است، تقریباً ۸۷٪ افرادی که به دلیل بیماری‌های قلبی به مراکز درمانی مراجعه می‌کنند، روش گوش دادن به صدای قلب را به عنوان یکی از

<sup>۱</sup>Ventricular Septal Defect (VSD)<sup>۲</sup>World Health Organization (WHO)

روش‌های غیر تهاجمی و ملایم در تشخیص قلمداد می‌کنند [۶]. استفاده از سیستم‌های مبتنی بر محاسبات کامپیوتری و تحلیل‌های نرم افزاری می‌تواند تا حد چشمگیری دقت و صحت تشخیص را افزایش دهد و لیکن مراجعات مکرر بیمار را به مراکز درمانی به حداقل خواهد رساند. شنیدن صداهای قلب معمولاً با استفاده از گوشی‌های طبی و یا ضبط از طریق دستگاه فونوکاردیوگراف انجام می‌شود. فونوکاردیوگراف، دستگاهی است که عملیات ضبط صدا در آن بر اساس نوسانات صوتی ناحیه قفسه سینه در اثر قلب و گردش خون می‌باشد [۷]. این دستگاه اطلاعات مفیدی را از وضعیت گردش خون قلب نیز به همراه دارد و ظرفیت‌های ویژه‌ای را از بیماری‌های قلب و عروق و امراض مرتبط با آن ارائه می‌دهد [۸]. شکل ۱ مراحل دریافت سیگنال از بدن انسان را نشان می‌دهد.

با این اوصاف در اندک پژوهشی از سوی محققان، تکیه بر شناسایی و تفکیک سیگنال‌های صوتی توأم با بیماری روزنه بین بطنی در قلب بوده و تحقیقات موجود در این زمینه با برخی ایرادات و مشکلات در عملکرد رو به رو هستند. به همین ترتیب می‌توان پیشنهاد نمود که سیستم خودکار باید این توانایی را در شناسایی بیماران همراه با روزنه بین بطنی که بیماری حادی شناخته می‌شود، کارآمد باشد.

هدف از روی آوردن به این موضوع، بررسی و معرفی عملی ابزاری جدید در پزشکی است که از آن در شناسایی آریتمی قلبی و یا نارسایی ناشی از سوراخ بین بطنی مبتنی بر تحلیل صدای ضبط شده از قلب استفاده گردد و با وجود غیر تهاجمی بودنش، دقت مناسبی را در اختیار پزشک قرار دهد. بنابراین به طور خلاصه اهداف به صورت زیر بیان می‌شوند:

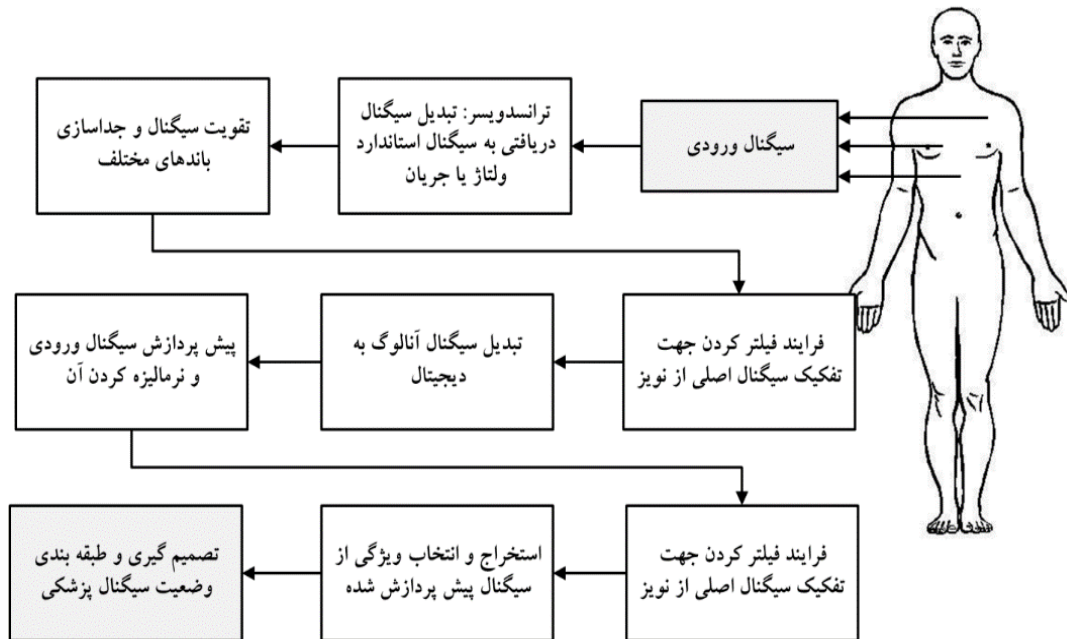
طراحی نرم افزاری در جهت شناسایی اختلال و یا بی نظمی ناشی از بیماری سوراخ بین بطنی با تکیه بر آنالیز سیگنال‌های صوتی قلب.

پیش بینی و تشخیص زودرس بیماری سوراخ بین بطنی با استفاده از مدلی هوشمند.

در مقاله حال حاضر با استفاده از داده‌های با ماهیت سیگنال صوتی قلبی در تشخیص خودکار بیماری روزنه بین بطنی قلب، سیستمی خودکار طراحی شده که با اعمال ویژگی‌های استخراج شده‌ای، زیرمجموعه‌ای بهینه انتخاب و در نهایت در مورد درجه تعلق به وجود یا عدم وجود سلامت فرد تصمیم‌گیری می‌شود. اهمیت موضوع آنجایی است که دقت روش‌های سابق کم است و عدم قطعیت بر تشخیص صحیح اثرگذار

در بخش چهارم، نتایج عملی حاصل از شبیه‌سازی توصیف می‌شود و در بخش پایانی، نتیجه‌گیری از تحقیق ارائه می‌شود.

خواهد بود [۸-۱]. در ادامه در بخش دوم، تحقیقات سایر محققین به همراه دستاوردهای آنها مورد بررسی قرار می‌گیرد و در بخش سوم، راهکار پیشنهادی ارائه خواهد شد. در ادامه



شکل (۱) - مراحل دریافت و پردازش سیگنال ورودی حیاتیاز بدن انسان.

## ۲- مروری بر تحقیقات پیشین

جداسازی سیگنال‌ها با استفاده از تجزیه ضرایب موجک و ساخت ۴ مولفه S1، S2، دوره انقباض و دوره انقباض کاری بود که توسط Liang و همکارانش [۶۱] انجام شده و در اصل با بکارگیری قاعده انرژی شانون و یک ماسک تعریف شده در واحد زمان، سیگنال و اجزای آن تخمین زده می‌شد. استخراج ویژگی با موجک و طبقه‌بند شبکه عصبی منجر به دقت متوسط رو به بالای ۸۵٪ شده و از سویی عدم قطعیت در کار آنها نامشخص است.

دکتر چانگ زنجیره پنهان مارکوف ارگادیک<sup>۱</sup> را برای شناسایی سیگنال‌های پیوسته صوتی قلب ارائه داد که سیکل‌های مختلف این سیگنال را اعم از S1، سیستول، S2 و دیاستول تفکیک می‌نمود [۱۲].

یکی از روش‌های تشخیص بیماری که توسط Maglogiannis و همکارانش [۱۳] در سال ۲۰۰۹ پیشنهاد شد، روشی بود که از ماشین بردار پشتیبان برای تحلیل سیگنال‌های صوتی قلب استفاده می‌نمود. در این تحقیق، استخراج ویژگی با موجک، طبقه‌بند ماشین بردار پشتیبان سبب دستیابی به دقت حداکثر ۹۱٪ شده است.

معمولاً بیماری نقص دیواره بین بطنی از خود صدای مور مور می‌سازد و برخی محققین تنها به تفکیک مور مور اکتفاء کرده‌اند و این مسئله سبب می‌شود تا نوع بیماری ناشناخته بماند. یکی از تحقیقاتی که در سال ۲۰۰۶ از سوی محققین ارائه شد، الگوریتمی بود که صدای اولیه قلب یا S1 را در یک سیکل چرخشی و با جداسازی سیگنال صوتی از محیط و صورت خودکار فراهم می‌کرد [۹]. آنها از نسبت S1 به S2 بهره برده‌اند و به همین علت، امکان تصحیح مکان سیگنال S1 فراهم می‌گردد. نحوه جداسازی S1 بر اساس تبدیل موجک بوده که خود منجر به تفکیک دو سیگنال مزبور شده است.

استفاده از تبدیل موجک در تحلیل سیگنال‌های صوتی قلب کار جدیدی نبوده و برخی دیگر از محققین چون Chebli و همکارانش [۱۰] از تبدیل گسسته آن در سال ۲۰۰۷ بهره بردند. تجزیه ضرایب موجک و طبقه‌بند رتبه‌ای منجر به دقت-های ۱۰۰٪/۸۹٪ و ۸۷٪ درصد برای سه کلاس حالت طبیعی، سیستولیک و دیاستول شده که البته مشخص نیست با چه سازوکاری این دسته‌بندی صورت پذیرفته است.

<sup>۱</sup>Ergodic Hidden Markov Model

و دقتی معادل ۹۳٪ را بدست آوردند. همچنین از انرژی شانون ضرایب نیز استفاده کردند تا با دقت بالاتری سیگنال مورد نظر را تشخیص دهند.

شمسی و همکارش [۲۲] در سال ۲۰۱۵ پیشنهاد کرده‌اند که به صورت برخط موقعیت صداها ی قلبی شناسایی گردد و آنها تفکیک اولیه سیگنال‌ها را بر اساس خوشه بند فازی C-means انجام دادند. از دیگر افرادی که می‌شود نام برد که به صورت شاخص به تحلیل بیماری نقص دیواره بین بطنی پرداختند، می‌توان به کار Reed و همکارانش در سال ۲۰۰۴ [۲۳]، Noponen و همکارانش [۲۴]، Akbari و همکارانش [۲۵]، Frank و همکارانش [۲۶]، Patidar و همکارانش [۲۷] اشاره نمود.

طبقه‌بند چندکلاسی ماشین بردار پشتیبان را Choi و همکارانش [۳۰]، یک‌بار دیگر در ترکیب تحلیل طیف خودبازگشتی جهت دسته‌بندی صداها ی قلبی نظیر مورمور مورد استفاده قرار دادند. داده‌های آنان شامل ۴۸۹ سیگنال صوتی با ۱۹۶ وضعیت نرمال و ۲۹۳ سیگنال غیرطبیعی بود. آنها عنوان کرده‌اند که روش پیشنهادی‌شان توانسته تا حد بسیار مناسبی وضعیت‌های بیماری و غیر آن را از مجموعه سیگنال‌های صوتی نمونه استخراج نماید.

استفاده از تکنیک‌ها و ابزارهای گذشته نیز کاری بوده که Yan و دیگر همکارانش جهت تفکیک و دسته‌بندی سیگنال‌های صوتی قلب از آن بهره بردند [۳۱]. در کار پیشنهادی آنها لحظه‌های به‌خصوص سیگنال صوتی قابل استنتاج بودند؛ به این معنی که استفاده از ابزار وضعیت موج لحظه‌ای و شاخص های آن تا حد زیادی، تفکیک هوشمند را فراهم نموده بود.

همچنین در همان سال، Amit و همکارانش [۳۲]، از روش خوشه‌بندی سلسله‌مراتبی به تفکیک سیگنال‌های مختلف صوتی قلب پرداختند و با دقت ۸۶٪ و انحراف معیار ۷٪ این نتیجه را در مرحله خوشه‌بندی بهینه نموده بودند. دقت مرحله طبقه‌بندی در حدود ۸۲٪ و با انحراف معیار ۶٪ بوده است.

علی‌رغم یادگیری در برخی از روش‌ها، دقت کم است، حساسیت و ویژگی به اندازه‌ای نیست که مرز مشخصی از عدم قطعیت حاصل آید و از سویی دقت‌های مراحل آموزش و آزمایش وارد نشده‌اند. در این روش‌ها سیگنال‌های قطعه‌بندی شده، محدودند و اغلب همپوشانی میان قطعات جدا شده از سیگنال صوتی در تشخیص بیماری لحاظ نشده است. جدول ۱ مقایسه ای بین روش‌های موجود را نشان می‌دهد.

در کار Maglogiannis و همکارانش، تمرکز بر روی شناسایی بیماری قلبی از روی صدای دریچه‌ها بوده و کاربرد ماشین بردار پشتیبان به عنوان یک طبقه‌بند مطرح شده است. آنها همچنین توانایی عملکرد این روش را با سایر طبقه‌بندهایی چون KNN مقایسه نموده‌اند.

در همان سال، Dokur و همکارانش [۱۴]، ویژگی‌های مهمی را برای صداها ی ضبط‌شده در نظر گرفتند که از یک پنجره یا ماسک برای استخراج بهترین ویژگی‌ها بهره می‌برد. فرایند به این ترتیب انجام می‌شد که در ابتدا صداها ی سیگنال S1 و S2 از یکدیگر تفکیک می‌شد و سپس پروسه نرمالیزه نمودن داده ها انجام می‌پذیرفت. فیلتر کردن بخش‌های همراه با نویز توسط تبدیل موجک صورت گرفته و از این‌رو موقعیت هر دو سیگنال نیز در سیگنال صوتی قلب پیدا شده بود. اما مشخصاً استخراج ویژگی‌ها با ماسک معرفی شده و بر مبنای فیلتر گذاری توان سیگنال و توان فیلتر گذاری سیگنال انجام شده بود. نتایج کار آنها در بردارنده عملکرد مناسب الگوریتم پیشنهادی بود.

طبقه‌بند چند کلاسی ماشین بردار پشتیبان را محققینی چون [۱۹-۱۵] در ترکیب تحلیل طیف خودبازگشتی جهت دسته بندی صداها ی قلبی نظیر مورمور مورد استفاده قرار دادند. آنها نیز عمدتاً یادگیری، نحوه تقسیم داده‌های آموزشی و آزمایشی، عدم قطعیت و نویز را کمتر مورد بحث قرار داده بودند و تنها به طبقه‌بندی و گزارش نتایج آن اکتفاء کرده بودند. به طور معمول دقت طبقه‌بندی در کار آنها از ۷۵٪ تا ۹۵٪ متغیر است.

همچنین Elgendi و همکارانش [۱۹] به ارائه راهکاری در شناسایی آریتمی‌های قلبی از سیگنال‌های صوتی پرداختند که مختص به یک رنج سنی خاص و آن هم کودکان بود. البته مواردی از کودکان که آنان انتخاب کرده بودند، مواردی با بیماری‌های پر تکرار نبود و شامل بیماری‌های بطنی قلب از نوع فشار خون بالا در شریان متصل به ریه می‌بود. نمونه داده‌ها، شامل کودکانی با رنج سنی از ۹ ماه تا ۱۹ سال بوده است و محاسبات جهت دستیابی به ویژگی‌های مناسب در حوزه فرکانس صورت پذیرفته است. ضرایب طیفی و آنالیز تفکیک کننده خطی منجر به دقت ۸۹٪ شده است.

در دو تحقیق در سال‌های ۲۰۱۴ و ۲۰۱۵، از سوی Hassani و همکارانش [۲۰ و ۲۱]، تفکیک و دسته‌بندی سیگنال‌های S1 و S2 با استفاده از تجزیه و بازسازی موجک مطرح و منتشر شد. آنها بر روی نمونه‌ای از داده‌ها کار خود را آزمایش نمودند

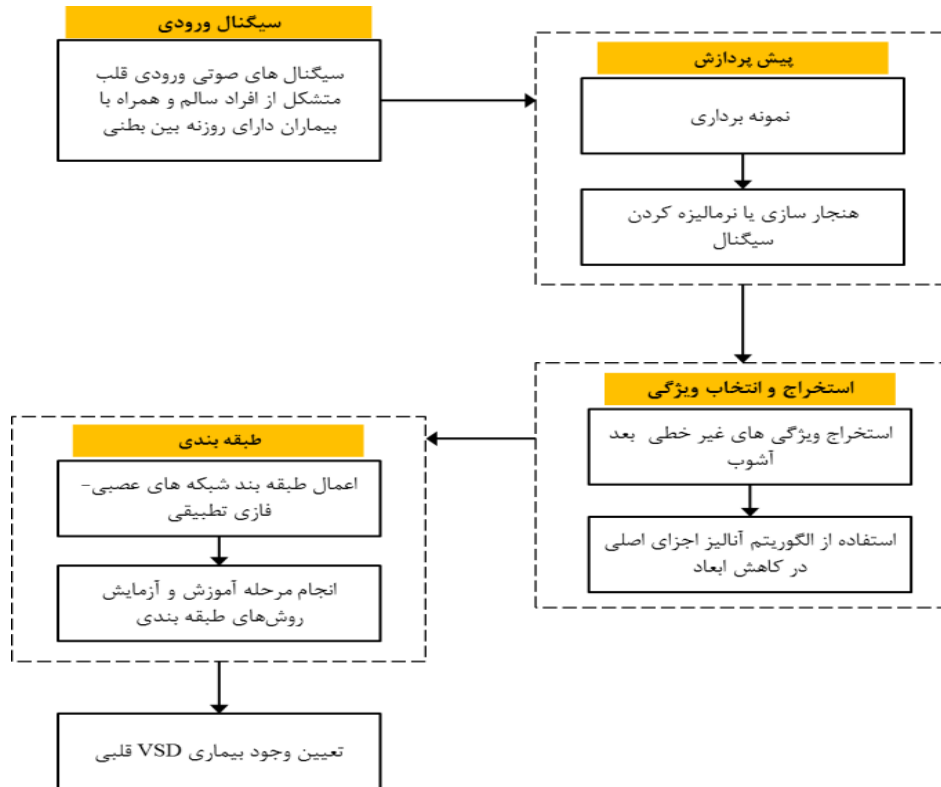
## جدول (۱) - مقایسه راهکارهای مورد استفاده در زمینه شناسایی بیماری‌های مختلف از سیگنال صوتی قلب.

طرح پیشنهادی (محقق)	داده‌های مورد بررسی	روش ارزیابی	سطح عملکرد
Wang و همکارانش	داده‌های کلینیکی	ردیابی زیر سطح‌ها و الگوریتم موجک	استفاده از انرژی شانون جهت حذف همپوشانی - دقت ۲۴/۹۳٪ و ۶۴/۸۱٪ $S_1$ و $S_2$ جداسازی برای دو حالت - میزان متغیر دقت و حساسیت کم
Chebli و همکارانش	داده‌های دانشگاه براینگتون	تجزیه ضرایب موجک و طبقه بند رتبه ای	دقت ۱۰۰٪ در جداسازی سیگنال طبیعی - دقت ۸۸٪ سیستم‌تولیک و ۸۹٪ دیسیستولیک
Liang و همکارانش	داده های کلینیکی	استخراج ویژگی با موجک- طبقه بند شبکه عصبی	دقت ۸۵٪ در تفکیک دو کلاس طبیعی و غیر طبیعی
Chung	داده های کلینیکی	مدل مخفی مارکوف یا شبکه بیزی پویا	دقت ۲۸/۹۹٪ برای داده های پیوسته
Maglogiannis و همکارانش	داده های کلینیکی	استخراج ویژگی با موجک- طبقه بند ماشین بردار پشتیبان	دقت ۸۷٪ تا ۹۱٪ برای مجموعه داده‌های کوچک
Dokur و همکارانش	داده های کلینیکی	استخراج ویژگی با طیف توان سیگنال - شبکه عصبی	دقت ۹۵٪ برای مجموعه داده‌های گردآوری شده خودشان
Choi و همکارانش	۴۸۹ سیگنال قطعه بندی شده کلینیکی	استخراج ویژگی با تخمین چگالی طیف توان و طبقه بندی با ماشین بردار پشتیبان	دقت ۹۹٪ برای مجموعه داده
و همکاران [۷۱] Yan	داده های کلینیکی	استخراج ویژگی با تجزیه ضرایب موجک و طبقه بندی مبتنی بر دانش	$S_1$ و $S_2$ دقت متغیر بین ۷۲٪ تا ۱۰۰٪ و مکان یابی
و همکاران (۵۶) Amit	۱۱ نفر داده‌های کلینیکی	استخراج ویژگی های زمانی و فرکانسی - طبقه بندی رگرسیونی	دقت ۸۵٪ با انحراف معیار ۷٪
و همکاران Naseri	داده‌های کلینیکی	محاسبات انرژی حوزه فرکانس-رتبه بندی	دقت ۹۹٪
Wang و همکاران	داده‌های کلینیکی در بیمارستان چین	ضرایب موجک-ماشین بردار پشتیبان	دقت ۸۸٪ برای مجموعه داده نمونه
Elgendi و همکارانش	داده‌های کلینیکی	ضرایب طیفی - آنالیز تفکیک LDAکنندخ خطی ( )	p-دقت ۸۹٪ و ضریب همبستگی مناسب (value<0.05)
Hassani و همکارانش	داده‌های دانشگاه تربیت مدرس	انرژی شانون و ضرایب موجک - طبقه بندی مبتنی بر دانش	دقت ۹۳٪ در تفکیک بین دو کلاس از داده‌های صوتی قلب
Shamsi و همکارش	داده های سالم از کلینیکی در ترکیه دریافت شده	خوشه بندی فازی	موقعیت یابی مولفه‌های سیگنال نمونه با دقت ۹۵٪
Reed و همکاران در سال ۲۰۰۴	داده‌های کلینیکی	تجزیه ضرایب موجک- شبکه های عصبی	دقت بالاتر از ۹۰٪
Noponen و همکاران	داده‌های کلینیکی	محاسبات انرژی و طیف توان- رتبه بندی	دقت بالای ۹۰٪

تخصصی قلب مورد استفاده قرار گیرد. مراحل پیاده سازی روش پیشنهادی، در شکل (۲) به صورت یک روندنما به نمایش درآمده است.

### ۳- روش پیشنهادی

همانگونه که اشاره شد، الگوریتم پیشنهادی در این مقاله، تکنیکی است که قابیت یادگیری دارد، مشکل عدم قطعیت را حل نموده و می‌تواند در مراکز بیمارستانی و کلینک‌های



شکل (۲) - ارائه راهکار پیشنهادی در پیش بینی بیماری روزنه بین بطنی قلب از سیگنال صوتی قلب.

۰/۷۵ تا ۱/۵ کیلوهرتز و ۰/۳۷۵ تا ۰/۷۵ کیلوهرتز به ترتیب در فواصل زمانی ۳/۵۱۶ تا ۵/۳۳۲ میلی ثانیه، ۵/۳۳۲ تا ۸/۲۴۲ میلی ثانیه، ۸/۲۴۲ تا ۱۲/۹ و ۱۲/۹ تا ۲۰/۱۹ میلی ثانیه قرار دارند که این محدوده از طریق منحنی زمان نهفتگی<sup>۱</sup> حاصل می‌آید.

### ۳-۲ هنجار سازی

صدای ضبط شده از قلب توسط دستگاه دو مرتبه نمونه برداری می‌شود و رزولوشن آن به فرکانس ۴KHz تقلیل پیدا می‌کند تا با استفاده از معادله معرفی شده در (۱) بتوان آنرا در فاصله [۱-۱۰] نرمالیزه نمود. دلیل اصلی نرمالیزه نمودن داده‌های اولیه، کمتر نمودن بازه تغییرات است تا از داشتن دامنه-

### ۳-۱ نمونه برداری

با استفاده از پنجره‌های زمانی که پس از آنالیز چند تفکیکی سیگنال به مقیاس‌های مختلف اعمال می‌گردد، می‌توان با دقت بیشتری سیگنال گسیل صوتی قلب را از نویز جداسازی نمود و نیز مراحل پردازشی بعدی آنرا ساده‌تر کرد. پنجره‌های زمانی بدست آمده مستطیلی هستند که مدت زمان آنها از روی منحنی زمان نهفتگی بدست می‌آید. برای اعمال پنجره‌های زمانی ابتدا سیگنال را با استفاده از توابعی پایه چون تبدیل موجک و یا آنالیزور ۵ بخشی به اجزای زمانی-فرکانسی-اش تجزیه کرده و با توجه به محدوده فرکانسی سیگنال گسیل‌های صوتی برانگیخته گذرای قلب را در مرحله نخست توسط پنجره‌های زمانی انتخاب شده به سیگنال اعمال می‌کنیم. پنجره‌های زمانی اعمال شده به شاخه‌های بانک فیلتری در محدوده فرکانس‌های ۳ تا ۶ کیلوهرتز، ۱/۵ تا ۳ کیلوهرتز،

<sup>۱</sup>Latency curve

روش Higuchi، تخمین قابل قبولی را از بعد فراکتال یا آشوب در مورد قسمت‌های کوتاه سیگنال با سرعت بالا ارائه می‌دهد. تخمین آنتروپی یک روش برای اندازه‌گیری میزان بی‌نظمی در یک سیستم است و بیشترین مقدار آن، نمایانگر بیشترین پیچیدگی و تصادفی بودن سیگنال است. هر چه قدر میزان آنتروپی تخمین زده شده کمتر باشد، رفتار منظم تری در داده‌ها وجود خواهد داشت که این نظم می‌تواند به معنای وجود بیماری و اختلالی چون روزنه بین بطنی در سیگنال صوتی قلب باشد. تخمین آنتروپی، یک روش غیر خطی در آنالیز سیگنال‌هاست که می‌توان آنرا از طریق تکنیک‌های رینی، شانون و پینکوس محاسبه نمود. آنتروپی رینی نقش مهمی در تئوری اطلاعات دارد و در واقع تعمیم یافته شانون است. همچنین این راهکار به عنوان ابزاری در کمی سازی تنوع و عدم قطعیت کاربرد دارد. آنتروپی رینی با درجه  $q$  برای توزیع احتمال داده شده از رابطه (۲) قابل دستیابی است:

$$S_q = \frac{1}{1-q} \log_2 \left( \sum_{i=1}^N P_i^q \right) \quad (2)$$

در این رابطه،  $P_i$  عضو مجموعه  $[0, 1]$  با توزیع احتمال هر کدام از مقادیر  $x_1, x_2, \dots, x_n$  است. برای چند مقدار  $q$ ، آنتروپی به گونه‌ای دیگر قابل محاسبه خواهد بود. اگر  $q=0$  باشد، آنگاه  $S_0 = \log_2(N)$  بوده که آنرا با نام آنتروپی هارتلی برای توزیع احتمال داده شده می‌شناسند. اگر  $q$  به سمت ۱ میل کند، آنگاه می‌توان نشان داد که  $S_q$  به  $S_1$  در رابطه (۳) که همان آنتروپی شانون است، همگرا خواهد شد:

$$S_1 = \sum_{i=1}^N P_i \log_2(P_i) \quad (3)$$

آنتروپی پینوکس مانند سایر آنتروپی‌ها میزان بی‌نظمی را در داده‌ها نمایش می‌دهد و این الگوریتم از بردارهای  $m$  بعدی  $x_i$  به طوری که  $i \leq N - m + 1 \geq 1$  و خواهیم داشت:

$$x_i = s(i), \dots, s(i+m-1) \quad (4)$$

در رابطه (۱۲)،  $s$  سری زمانی اصلی با  $N$  نمونه است. با استفاده از ثابت مثبت  $\tau$ ،  $C_i^m(r)$  مطابق رابطه (۵) محاسبه می‌شود:

$$C_i^m(r) = \frac{N_{x_j}}{N - m + 1} \quad (5)$$

های بالا در هنگام تحلیل است اجتناب گردد. این کار نه تنها بر دقت طبقه بندی اثر می‌گذارد، بلکه حجم محاسبات را نیز کمتر می‌کند.

$$D_{norm}(t) = \frac{D_{4KHz}(t)}{\max(D_{4KHz}(t))} \quad (1)$$

در این معادله  $D_{4KHz}(t)$  سیگنال نمونه برداری شده پس از تقلیل فرکانس و همچنین  $D_{norm}(t)$  سیگنال نرمالیزه شده نامیده می‌شود. در برخی مطالعات، اعتقادی به نرمالیزه سازی و یا استاندارد کردن سیگنال ورودی نیست و برخی از تحقیقات تنها به نمونه برداری رو به پایین<sup>۱</sup> اکتفاء می‌کنند.

### ۳-۳ استخراج ویژگی با مدل آشوب

با وصف آنکه روش‌های مختلفی در زمینه استخراج ویژگی در سیگنال‌های نمونه‌ای صوتی وجود دارد، اما ویژگی‌های غیر خطی بهترین راه حل برای توصیف یک سیگنال صوتی به حساب می‌آیند [۲۸]. بنابراین برای کار حال حاضر از تکنیک آشوب<sup>۲</sup> برای توصیف سیگنال‌های صوتی قلب استفاده نموده- ایم. از ویژگی‌های کارآمد در این مجموعه ویژگی‌ها می‌توان به ویژگی‌های غیر خطی بعد همبستگی، بعد فراکتال و آنتروپی و ویژگی‌های فضای فاز استفاده می‌شود. به سبب آنکه از ویژگی‌های غیر خطی در آنالیز اولیه سیگنال استفاده کرده‌ایم، آنها را جداگانه تشریح می‌کنیم. در روش نخست، در ابتدا فاصله بین هر جفت از نقاط داخل فضای فاز تعیین می‌شود و سپس انتگرال همبستگی تخمین زده می‌شود.

در واقع، ما در بعد فراکتال از یکی دیگر از روش‌های موجود در تعیین پیچیدگی در یک سیگنال استفاده می‌کنیم. درجه پیچیدگی یک سیگنال متناسب با بعد افزایش می‌یابد. بعد فضای حالت هر پدیده کاملاً وابسته به دینامیک آن پدیده می‌باشد. به همین منظور، مشخص شدن مقدار بعد پدیده، یکی از گام‌های مهم و اساسی در جهت شناسایی محدوده رفتارهای دینامیکی آن خواهد بود. الگوریتم‌های زیادی برای محاسبه بعد فراکتال وجود دارد که از آن جمله می‌توان به الگوریتم پتروسین<sup>۳</sup>، کتز<sup>۴</sup> و هیگوچی<sup>۵</sup> اشاره نمود.

<sup>۱</sup>Down-Sampling

<sup>۲</sup>Fractal

<sup>۳</sup>Petrosian

<sup>۴</sup>Katz

<sup>۵</sup>Higuchi



که در آن  $\Pi$  و  $P$  به ترتیب ماتریس قطری مقادیر ویژه و ماتریس مقادیر ویژه متعامد است. از لحاظ هندسی،  $P$  یک ماتریس چرخشی است که دستگاه مختصات اصلی را بر اساس بردارهای ویژه می‌چرخاند، به طوری که بردار مقادیر ویژه با بزرگترین مقدار بردار همبسته می‌شود که در این صورت آنرا محور واریانس بیشینه می‌نامند. تنها مقادیر ویژه  $\beta$  با بزرگترین مقادیر ویژه همبسته می‌شود که در آن صورت برای تعریف زیرفضا مورد استفاده قرار می‌گیرد و در آن  $\beta$  ابعاد زیر فضای مورد انتظار است. سه عامل برای تطبیق دادن تصویر در زیرفضای بردارهای ویژه  $\beta$  وجود دارد. بنابراین برای کاستن میزان محاسبات از کاستن ابعاد استفاده می‌کنند.

به همین ترتیب محورهای بعدی عمود بر تمامی محورهای قبلی به گونه‌ای قرار می‌گیرند که داده‌ها در آن جهت دارای بیشترین پراکندگی باشند. پس می‌توان در میان داده‌های استخراج شده توسط الگوی باینری محلی، ویژگی‌های که از بقیه با اهمیت‌تر هستند را تفکیک نمود. پس میزان محاسبات کمتر می‌شود و از میزان دقت نیز کاسته نخواهد شد. اولین محور باید در جهتی قرار گیرد که واریانس داده‌ها بیشینه شود بعبارت دیگر محور در جهتی قرار می‌گیرد که پراکندگی داده‌ها بیشتر است. دومین محور باید عمود بر محور اول به گونه‌ای قرار گیرد که واریانس داده‌ها نیز بیشینه شود. به همین ترتیب محورهای بعدی عمود بر تمامی محورهای قبلی به گونه‌ای قرار می‌گیرند که داده‌ها در آن جهت دارای بیشترین پراکندگی باشند.

### ۳-۵ طبقه‌بندی

یکی از ابزارهای کارآمد در شناسایی ارتباطات بین متغیرها، استفاده از تکنیک استنتاج عصبی-فازی تطبیقی است که ساختاری مشابه شبکه عصبی و سیستم‌های فازی دارد و از لحاظ ساختار و پیکره بندی به شبکه‌های عصبی شبیه است. آموزش ANFIS با استفاده از دو الگوریتم پس انتشار خطا<sup>۱</sup> و یا الگوریتم ترکیبی که مشتمل بر دو الگوریتم تخمین حداقل مربعات خطا و پس انتشار خطاست، انجام می‌پذیرد و پارامترهای توابع عضویت را تخمین خواهد زد. اگر فرض شود که سیستم فازی دارای دو ورودی  $x$  و  $y$ ، و خروجی آن  $z$  در نظر گرفته شود، قوانین به صورت رابطه (۱۰) نگاشته می‌شوند:

$$\begin{aligned} R(1): & \text{If } x \text{ is } A_1 \text{ and } y \text{ is } B_1 \text{ then } f_1 = p_1 x + q_1 y \\ R(2): & \text{If } x \text{ is } A_2 \text{ and } y \text{ is } B_2 \text{ then } f_2 = p_2 x + q_2 y \end{aligned} \quad (10)$$

در این رابطه،  $N_{x_j}$  تعداد  $x_j$ های است که فاصله آن با  $x_i$ ها کمتر از مقدار  $r$  است. در واقع این فاصله را فاصله بین دو بردار می‌دانیم و از سویی مطابق با رابطه (۶)،  $Q^m(r)$  قابل بیان است:

$$Q^m(r) = \frac{1}{N-M+1} \sum_{i=1}^{N-m+1} P_i \ln C_i^m(r) \quad (6)$$

در نهایت، آنتروپی مطابق رابطه (۷) قابل محاسبه خواهد بود:

$$ApEn = Q^m(r) - Q^{m+1}(r) \quad (7)$$

باید در نظر داشت که مقادیر  $m$  و  $r$  می‌تواند باعث تغییر نتایج گردد. ما بر اساس پیشنهاد خود پینوکس، مقدار  $r$  را تقریباً  $0.2$  انحراف استاندارد در نظر گرفته‌ایم. به این ترتیب مجموعه ویژگی‌های کارآمدی را می‌توان از سیگنال صوتی قلب دریافت نمود و وارد فاز انتخاب ویژگی خواهیم شد.

### ۳-۴ کاهش ابعاد

پس از استخراج ویژگی و ساخت بردار ویژگی‌ها، از تکنیک کاهش بعد توسط الگوریتم آنالیز اجزای اصلی استفاده می‌شود. روش آنالیز اجزای اصلی روشی بدون ناظر و تبدیلی خطی به حساب می‌آید که داده‌های ورودی را به فضایی ویژه نگاشت می‌سازد. با فرض آنکه  $M$  نمونه آموزشی در اختیار باشد، ماتریس داده‌های تصویری بر اساس  $X = x_1, x_2, \dots, x_m$  شکل می‌گیرد و ترانهاده این ماتریس  $Y$  نامیده می‌شود که در آن  $Y = XT$  خواهد بود. مرکز داده‌ها در فضای تصویر با استفاده

از بردار میانگین  $m = \frac{1}{M} \sum_{j=1}^m X_j$  حاصل خواهد آمد. سپس به کم کردن بردار میانگین  $m$  از هر بردار آموزش که به فرم  $x_j = (x_j - m)$  نمایش داده می‌شود، می‌توان ماتریس داده‌های ستونی را بر اساس  $x_c = \bar{x}_1, \bar{x}_2, \dots, \bar{x}_m$  تشکیل داد که آنرا بردار شاهد نیز می‌نامند. ماتریس کوواریانس مجموعه داده‌ها از رابطه (۸) بدست می‌آید:

$$Cov_x = \frac{1}{M} \sum_{j=1}^m \bar{x}_j \bar{x}_j^T = \frac{1}{M} x_c x_c^T \quad (8)$$

با قطری کردن  $Cov_x$  مولفه‌های اصلی بدست می‌آیند که این مولفه‌ها تصویر متعامد روی بردارهای ویژه هستند و با حل معادله مقادیر ویژه محاسبه می‌شوند.

$$P^T Cov_x P = \Pi \quad (9)$$

<sup>۱</sup>Back Propagation

بطنی در آن وجود دارد اما نرم افزار شبیه سازی شده به اشتباه عدم وجود بیماری را بازشناسی نموده است.

که در این معادلات، NTP تعداد درستی‌های مثبت، NTN تعداد درستی‌های منفی، NFP تعداد خطاهای مثبت و NFN تعداد خطاهای منفی در تشخیص بیماری قلبی در نمونه‌های داده‌ای روزنه بین بطنی است.

بهترین تعداد اعضای انتخاب شده ویژگی‌های تجمیع یافته توسط آنالیز اجزای اصلی در فاصله ۱۸ تا ۲۵ ویژگی، کمترین میزان خطای طبقه‌بندی را به همراه داشتند. از این رو تعداد ویژگی‌ها در ۶ گروه ۴ تایی ذخیره شد و ویژگی‌های برگزیده، ورودی پیکره ANFIS شدند. جهت شبیه سازی ANFIS، از پیکره نمایش داده شده در شکل (۳) با توصیف لایه‌های ذکر شده استفاده گردید:

**لایه ۱:** در این لایه ورودی‌ها بر اساس رابطه (۲۴) از توابع عضویت عبور می‌کنند:

$$\begin{aligned} O_{1,i} &= \mu A_i(x), & \text{for } i=1,2 \\ O_{1,i} &= \mu B_i(x), & \text{for } i=3,4 \end{aligned} \quad (12)$$

توابع عضویت هر تابع پارامتری مناسبی می‌تواند در نظر گرفته شود و در اکثر موارد توابع گوسین انتخاب می‌شوند. مثل تابع زنگی شکل عمومی که مطابق رابطه (۲۰) معرفی شده است:

$$\mu_{A(x)} = \frac{1}{1 + \left| \frac{x - c_i}{a_i} \right|^{2b_i}} \quad (13)$$

که، مجموعه  $\{a_i, b_i, c_i\}$  مجموعه پارامترها هستند.

**لایه ۲:** خروجی این لایه ضرب سیگنال‌های ورودی است که در واقع معادل قسمت اگر قوانین هستند و مطابق با رابطه (۲۱) تعریف می‌گردد:

$$O_{2,i} = w_i = \mu A_i(x) \mu B_i(y), \quad i=1,2 \quad (14)$$

**لایه ۳:** خروجی این لایه نرمالیزه شده لایه ۲ است و مطابق رابطه (۲۲) معرفی می‌گردد:

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i=1,2 \quad (15)$$

**لایه ۴:** در لایه ۴ نیز که قبل از خروجی است، داریم:

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (16)$$

**لایه ۵:** خروجی این لایه خروجی کلی سیستم است و بر اساس رابطه (۱۷) قابل نمایش است:

$$O_{5,i} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (17)$$

و اگر برای غیر فازی ساز از غیر فازی ساز میانگین مراکز استفاده شود، خروجی به صورت مجموعه روابط قید شده در (۱۱) مورد استفاده خواهد بود:

$$\begin{aligned} f &= \frac{w_1 f_1 + w_2 f_2}{w_1 + w_2} = \bar{w}_1 f_1 + \bar{w}_2 f_2 \\ \bar{w}_1 &= \frac{w_1}{w_1 + w_2}, \quad \bar{w}_2 = \frac{w_2}{w_1 + w_2} \end{aligned} \quad (11)$$

### ۳-۶ نتایج عملی و تفسیر نتایج

بطور کلی در سیستم‌های هوشمندی که قابلیت دسته‌بندی، تشخیص و جداسازی داده‌های هدف از سایر داده‌ها را بر عهده دارند، جهت بررسی میزان موفقیت و کارایی آنها از ماتریس کانفیوژن و نمودار منحنی عامل گیرنده استفاده می‌شود [۲۹]. برای تحلیل ماتریس کانفیوژن در مورد دسته‌بندی و تشخیص داده‌های هدف و سایر داده‌های غیر هدف، چهار حالت مثبت حقیقی<sup>۱</sup>، منفی حقیقی<sup>۲</sup>، مثبت کاذب<sup>۳</sup>، منفی کاذب<sup>۴</sup> که هر کدام از این مقادیر در ماتریس کانفیوژن مفهومی ویژه دارند. در مرحله نخست، جهت برآورد ماتریس مذکور، از بررسی حالات مختلف در زمان جداسازی و شناسایی بیماری روزنه بین بطنی قلبی محتمل صورت می‌پذیرد. البته گاهی عبارات موجود در ماتریس به هم ریخته را به ترتیب با نام‌های درستی مثبت، درستی منفی، اشتباه مثبت و اشتباه منفی نیز می‌شناسند؛ این ۴ عبارت به صورت زیر بیان می‌گردند:

(الف) درستی مثبت یا مثبت حقیقی (TP): تعداد نمونه‌هایی دریافت شده است که علائم احتمالی روزنه بین بطنی در آن وجود دارد و نرم افزار شبیه سازی شده به درستی توانسته وجود بیماری را بازشناسی نماید.

(ب) درستی منفی یا منفی حقیقی (TN): تعداد نمونه‌هایی از نمونه‌های نمایانگر روزنه بین بطنی است که علائم بیماری در آن وجود ندارد و نرم افزار شبیه سازی شده به درستی توانسته عدم وجود بیماری را بازشناسی کند.

(ج) مثبت کاذب یا اشتباه مثبت (FP): تعداد نمونه‌هایی از نمونه‌های نمایانگر روزنه بین بطنی است که علائم بیماری در آن وجود ندارد اما نرم افزار شبیه سازی شده به اشتباه وجود بیماری روزنه بین بطنی را بازشناسی نموده است.

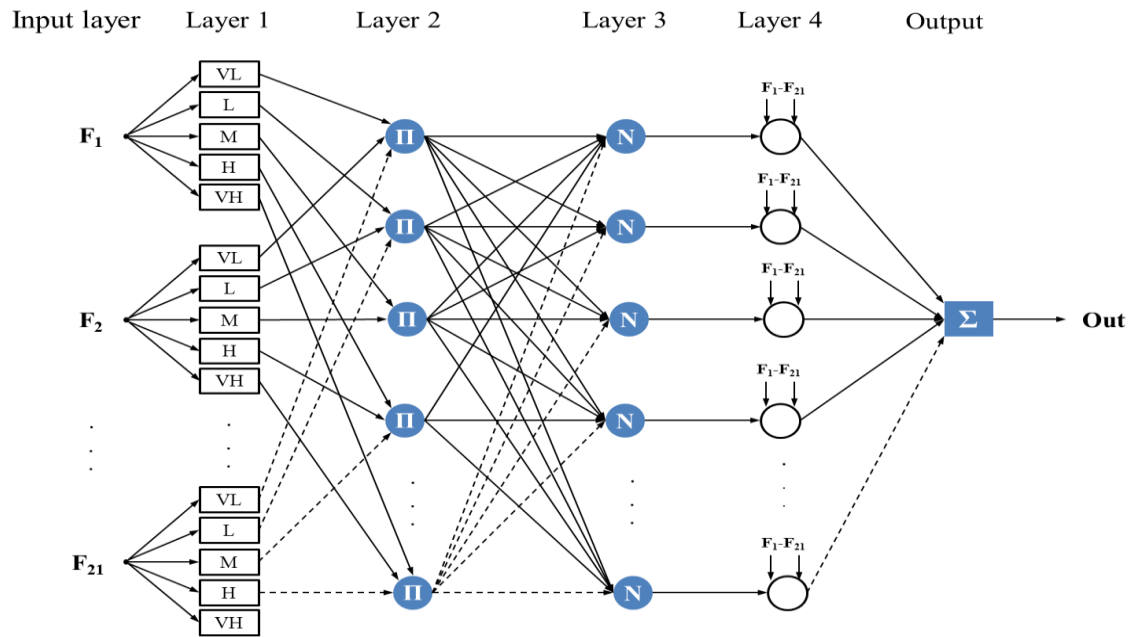
(د) منفی کاذب یا اشتباه منفی (FN): تعداد نمونه‌هایی از نمونه‌های نمایانگر بیماری است که علائم بیماری روزنه بین

<sup>۱</sup>True Positive(TP)

<sup>۲</sup>True Negative(TN)

<sup>۳</sup>False Positive(FP)

<sup>۴</sup>False Negative(FN)

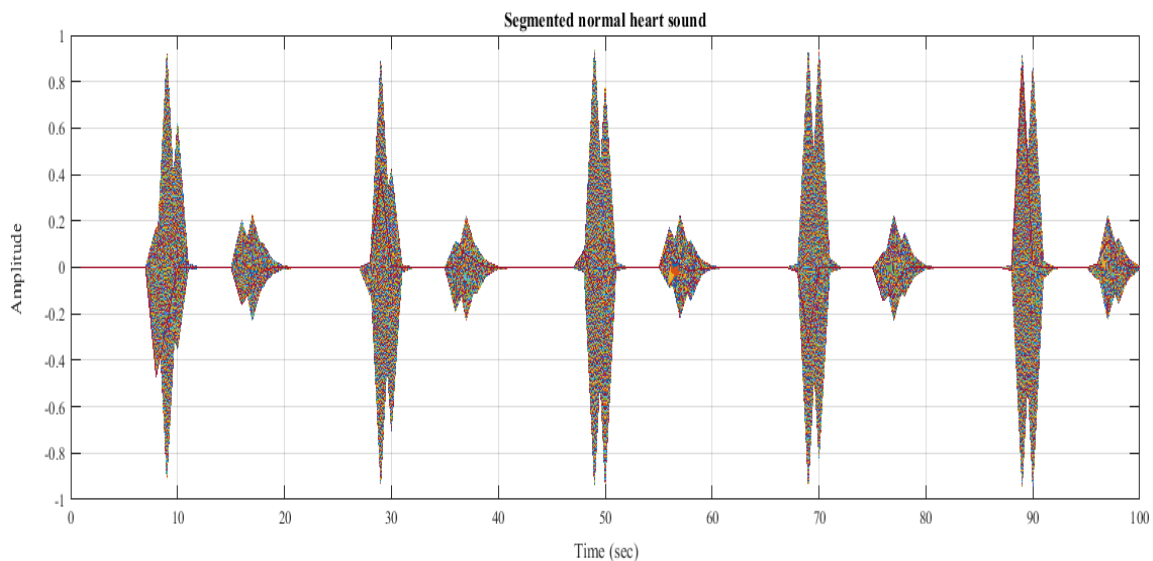


شکل (۳) - پیکره ANFIS پیشنهادی در طبقه‌بندی سیگنال‌های صوتی قلب در تشخیص روزنه بین بطنی.

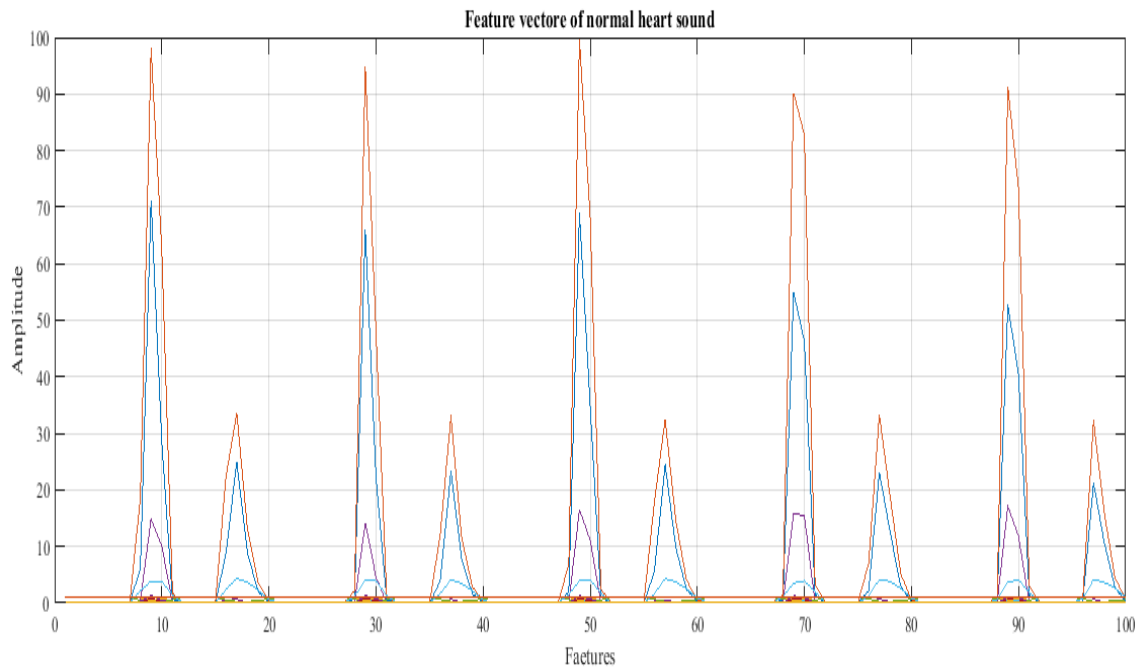
انجام می‌شود. قاب‌های طبیعی نیز دارای ۵۰ میلی ثانیه طول و ۵ میلی ثانیه همپوشانی با سیگنال بعد از خود دارند. ۲۰٪ همپوشانی در نظر گرفته شده، مطابق با استانداردهای پردازش گفتار و پردازش سیگنال‌های صوتی است. ۱۷۱ قاب از وضعیت طبیعی و ۱۵۳ قاب صوتی نمایانگر بیماری نقص بین بطنی بوده که جهت ارزیابی آنها، داده‌ها به روش اعتبارسنجی K-fold ارزیابی می‌شوند.

در شکل‌های (۳) و (۴) به ترتیب سیگنال قطعه بندی شده و بردار ویژگی‌های استخراج شده سیگنال طبیعی نمونه برای یک فرد به نمایش درآمده است.

مجموعه داده‌ها شامل ۲ سیگنال ضبط شده از ۲ نفر بیمار مشکوک به نقص بین بطنی بوده که پزشک متخصص وجود بیماری را در آنها قبلاً تایید نموده است. همچنین از دو سیگنال افراد سالم به عنوان سیگنال‌های شاهد استفاده گردید. هر یک از سیگنال‌ها به حدوداً ۷۰۰ قطعه ۵۰ میلی ثانیه‌ای (دقیقاً ۱۵۳ قطعه مجزا) تقسیم شدند و قاب‌های تشکیل دهنده، با یکدیگر ۵ میلی ثانیه همپوشانی داشتند. این قاب‌ها جهت آنکه نقطه شروعشان با سایر قاب‌ها هم فاز گردد، ۵ میلی ثانیه همپوشانی دارند. از طرفی برای افراد سالم (دقیقاً ۱۷۱ قاب مجزا) قطعه صوتی از قلب تشکیل مانند حالت پیش



شکل (۴) - نمونه سیگنال قطعه بندی شده برای تشکیل قاب‌های مورد استفاده در مرحله استخراج ویژگی.



شکل (۵) - بردار ویژگی‌های استخراج شده از هر قاب ورودی

جدول (۲) - ارزیابی الگوریتم در گام بازشناسی وجود بیماری بین بطنی در سیگنال‌های صوتی توسط روش آشوب-انفیس توسط اعتبار سنجی چند لایه‌ای در گروه ۱ (مرحله آموزش)

Spec	Acc	F score	Pre	FN	FP	TN	TP	K	K-fold مرحله آموزش
۹۱۴۳/۰	۹۱۷۵/۰	۹۲۰۵/۰	۹۲۰۵/۰	۱۲	۱۲	۱۲۸	۱۳۹	۱	
۹۷۷۹/۰	۹۶۵۶/۰	۹۶۷۳/۰	۹۸۰۱/۰	۷	۳	۱۳۳	۱۴۸	۲	
۹۳۷۱/۰	۹۴۸۵/۰	۹۴۹۸/۰	۹۴۰۴/۰	۶	۹	۱۳۴	۱۴۲	۳	
۹۶۴۰/۰	۹۶۲۲/۰	۹۶۳۷/۰	۹۶۶۹/۰	۶	۵	۱۳۴	۱۴۶	۴	
۹۷۷۴/۰	۹۵۵۳/۰	۹۵۷۹/۰	۹۸۰۱/۰	۱۰	۳	۱۳۰	۱۴۸	۵	
۹۵۵۶/۰	۹۴۱۴/۰	۹۴۴۶/۰	۹۶۰۳/۰	۱۱	۶	۱۲۹	۱۴۵	۶	
۹۵۵۹/۰	۹۴۵۰/۰	۹۴۷۷/۰	۹۶۰۳/۰	۱۰	۶	۱۳۰	۱۴۵	۷	
۹۴۴۴/۰	۹۵۸۸/۰	۹۵۹۷/۰	۹۴۷۰/۰	۴	۸	۱۳۶	۱۴۳	۸	
۹۲۰۳/۰	۹۱۷۵/۰	۹۲۱۱/۰	۹۲۷۲/۰	۱۳	۱۱	۱۲۷	۱۴۰	۹	
۹۵۰۷/۰	۹۵۸۸/۰	۹۶۰۰/۰	۹۵۳۶/۰	۵	۷	۱۳۵	۱۴۴	۱۰	
۹۴۹۸/۰	۹۴۷۱/۰	۹۴۹۲/۰	۹۵۳۶/۰	۸۴	۷۰	۱۳۱۶	۱۴۴۰	مجموع	

می‌توانیم پارامترهای حاوی اطلاعات قابل استخراج از یک بردار احتمالاتی را در مورد عدم قطعیت در یک عدد خلاصه نماییم. این معیار به صورت معادله (۲۵) قابل بیان است:

$$H(x) = -\sum_{i=1}^k p(x_i) \log_2 p(x_i), \quad i=1,2,3,\dots,k \quad (25)$$

و همچنین داریم:

$$p(x_i) = [p(x_1), p(x_2), p(x_3), \dots, p(x_k)] \quad (18)$$

جهت آنکه به خروجی‌ها اعتماد شود و بدانیم که آیا عدم قطعیتی با درجه بالا در مورد آنها به گونه‌ای وجود دارد که این دقت‌ها قابل استناد نیستند، رخ می‌دهد یا خیر از آنالیز عدم قطعیت و محاسبه مقدار  $p$  استفاده می‌کنیم. معیار آنتروپی میزان تصادفی بودن یا وقوع اتفاقی یک پدیده را نمایش می‌دهد و بر اساس آن می‌توان رخداد واقعی یک پدیده را ادعا نمود. به عبارت دیگر با استفاده از این معیار،

<sup>1</sup> p-Value

جدول (۳) - ارزیابی الگوریتم در گام بازشناسی وجود بیماری بین بطنی در سیگنال‌های صوتی توسط روش آشوب-انفیس توسط اعتبار سنجی چند لایه‌ای K-fold در گروه ۱ (مرحله آزمایش)

Spec	Acc	F score	Re	Pre	FN	FP	TN	TP	K	K-fold مرحله آزمایش
۰/۹۲۳۱	۰/۹۳۹۴	۰/۹۵۰۰	۰/۹۵۰۰	۰/۹۵۰۰	۱	۱	۱۲	۱۹	۱	
۰/۸۵۷۱	۰/۹۰۹۱	۰/۹۲۳۱	۰/۹۶۷۴	۰/۹۰۰۰	۱	۲	۱۲	۱۸	۲	
۰/۸۳۳۳	۰/۸۷۵۰	۰/۹۰۰۰	۰/۹۰۰۰	۰/۹۰۰۰	۲	۲	۱۰	۱۸	۳	
۰/۸۵۷۱	۰/۹۰۹۱	۰/۹۲۳۱	۰/۹۶۷۴	۰/۹۰۰۰	۱	۲	۱۲	۱۸	۴	
۰/۸۴۶۲	۰/۸۷۸۸	۰/۹۰۰۰	۰/۹۰۰۰	۰/۹۰۰۰	۲	۲	۱۱	۱۸	۵	
۰/۹۲۸۶	۰/۹۶۹۷	۰/۹۷۴۴	۱/۰۰۰۰	۰/۹۵۰۰	۰	۱	۱۳	۱۹	۶	
۰/۸۵۷۱	۰/۹۰۹۱	۰/۹۲۳۱	۰/۹۶۷۴	۰/۹۰۰۰	۱	۲	۱۲	۱۸	۷	
۰/۹۲۳۱	۰/۹۳۹۴	۰/۹۵۰۰	۰/۹۵۰۰	۰/۹۵۰۰	۱	۱	۱۲	۱۹	۸	
۰/۹۲۸۶	۰/۹۶۹۷	۰/۹۷۴۴	۱/۰۰۰۰	۰/۹۵۰۰	۰	۱	۱۳	۱۹	۹	
۰/۹۲۳۱	۰/۹۳۹۴	۰/۹۵۰۰	۰/۹۵۰۰	۰/۹۵۰۰	۱	۱	۱۲	۱۹	۱۰	
۰/۹۲۳۱	۰/۹۳۹۴	۰/۹۵۰۰	۰/۹۴۹۲	۰/۹۲۵۰	۱۰	۱۵	۱۱۹	۱۸۵	مجموع	
۰/۸۸۷۷	۰/۹۲۳۹	۰/۹۳۶۸								

صورت بلادرنگ عمل نماید. برخی روش‌ها نیز بر تقسیم مشخص داده‌ها دست نگذاشته‌اند و تنها به محک سیستم با نسبت‌های تجربی تقسیم دوسوم آموزش-یک سوم آزمایش بسنده نموده‌اند؛ در حالی که در اینجا از ارزیابی متقاطع K-fold استفاده شده است. در جدول (۴) چند نمونه از کارهای که طی سال‌های اخیر توسط محققین در پیش بینی بیماری پیشنهاد شده، به نمایش درآمده است.

جدول (۴): راه حل پیشنهادی در مقایسه با جدول ۱ که شامل کارهای قبلی بود.

طرح پیشنهادی (محقق)	داده‌های مورد بررسی	روش ارزیابی	سطح عملکرد
راهکار کنونی	مجموعه داده‌های دانشگاه میشیگان	استخراج ویژگی با موجک-طبقه بند انفیس-انتخاب ویژگی آنالیز اجزای اصلی و ارزیابی با K-fold روش برابر ۱۰	حساسیت معادل ۱۴/۹۵٪ در مرحله آموزش و ۲۷/۹۵٪ در مرحله آزمایش با خطای مثبت ۴۹/۷ در مرحله آموزش و ۳۳/۹ در مرحله آموزش برای بیماری نقص بین بطنی

که در این دو معادله،  $p(x_i)$  احتمال وقوع (درجه تعلق حاصل از خوشه بند یا طبقه‌بند) یک پدیده و در اینجا درجه تعلق به کلاس وقوع بیماری روزنه بین بطنی یا عدم وقوع است. با محاسبه عدم قطعیت توسط معیار آنتروپی، این معیار برای مراحل آموزش و آزمایش هر دو بالاتر از ۹۰٪ حاصل آمد که نمایانگر عملکرد مناسب سیستم پیشنهادی است. لیکن الگوریتم به سبب اشتباه در تشخیص وضعیت‌های مشابه با بیماری دچار خطا می‌شود و به همین دلیل، خطاهای مثبت بالا بوده و همین امر سبب کم شدن دقت مجموع در آموزش و آزمایش گردیده است. در روش‌های سابق، مشکلی که در این تحقیق وجود دارد، محرز است و این اتفاق به سبب ذات خود داده‌ها و شباهت حالات عادی به حالات خطر بیماری است. گاهی، محققین دقت‌های کمتر از این مقادیر دقت آموزش و آزمایش را بدست آورده‌اند [۲۸-۱۱] و حتی در پاره-ای از موارد به فرایند یادگیری و سیستم پیشگو توجه نشده است و از عدم قطعیت در دستیابی به جواب‌ها سخنی به میان نیامده است. به سبب وجود مرحله پیش پردازش در اینجا، امکان حذف نویز و یا داده‌های اشتباهی که ممکن است با داده‌های اصلی همراه گردند، وجود دارد؛ در حالی که در روش‌های سابق، ممکن است بروز نویز در داده‌ها به شدت بر سیستم اثرگذار باشد. تعداد کمی از ویژگی‌ها مورد استفاده قرار گرفته‌اند؛ این کار نوعاً تا حدودی دقت را افزایش می‌دهد و از سویی، زمان پردازش اطلاعات را کم می‌کند تا سیستم به

## ۴- نتیجه گیری

آنچه مشخص است، کم کردن خطاهای مثبت برای مجموعه داده حال حاضر فرایندی سخت به نظر می‌رسد. اما با توجه به آنکه در الگوریتم پیشنهادی تا حد چشمگیری اثر خطاهای منفی کم شده و دقت افزایش یافته است. در کار حال حاضر، تمرکز بر تفکیک صحیح داده‌ها بوده و با انتخاب روش ارزیابی K-fold (K=10) سعی در محک داده‌ها در چند گام و طی تقسیم به بخش‌های آموزشی و آزمایشی بوده‌ایم. الگوریتم‌های بهینه سازی و به ویژه الگوریتم استخراج ویژگی‌ها با کمترین حجم ممکنه (۱۸ تا ۲۵ ویژگی از میان ۵۰ ویژگی) برگزیند تا سیستم طبقه‌بندی با دقت بالاتر از ۹۲٪ امکان پیش‌بینی بیماری روزنه بین بطنی را داشته باشد. پیش‌بینی این رخداد تا حد زیادی می‌تواند از بروز عوارض منجر به مرگ را در نوزادان، کودکان و افراد بزرگسال به صورت غیر تهاجمی بکاهد. در آینده قصد بر آن است که دقت تشخیص به واسطه کم کردن خطای مثبت افزایش یابد و تاخیر در پاسخگویی تا حد زیادی کاسته شود.

## ۵- مراجع

- Physiological Considerations, Third Edition, 148-178.
- [9] Wang, P., Kim, Y., Ling, L. H., & Soh, C. B. (2006, January). First heart sound detection for phonocardiogram segmentation. In 2005 IEEE Engineering in Medicine and Biology 27th Annual Conference (pp. 5519-5522). IEEE.
- [10] Chebil, J., & Al-Nabulsi, J. (2007). Classification of heart sound signals using discrete wavelet analysis. *International Journal of Soft Computing*, 2(1), 37-41.
- [11] Liang, H., & Nartimo, I. (1998, October). A feature extraction algorithm based on wavelet packet decomposition for heart sound signals. In *Time-Frequency and Time-Scale Analysis, 1998. Proceedings of the IEEE-SP International Symposium on* (pp. 93-96). IEEE.
- [12] Chung, Y. J. (2007, June). Classification of continuous heart sound signals using the ergodic hidden Markov model. In *Iberian Conference on Pattern Recognition and Image Analysis* (pp. 563-570). Springer Berlin Heidelberg. Chicago.
- [13] Maglogiannis, I., Loukis, E., Zafiroopoulos, E., & Stasis, A. (2009). Support vectors machine-based identification of heart valve diseases using heart sounds. *Computer methods and programs in biomedicine*, 95(1), 47-61.
- [14] Dokur, Z., & Ölmez, T. (2009). Feature determination for heart sounds based on divergence analysis. *Digital Signal Processing*, 19(3), 521-531.
- [15] Yan, Z., Jiang, Z., Miyamoto, A., & Wei, Y. (2010). The moment segmentation analysis of heart sound pattern. *Computer methods and programs in biomedicine*, 98(2), 140-150.
- [16] Amit, G., Gavriely, N., & Intrator, N. (2009). Cluster analysis and classification of heart sounds. *Biomedical Signal Processing and Control*, 4(1), 26-36.
- [17] Naseri, H., & Homaeinezhad, M. R. (2013). Detection and boundary identification of phonocardiogram sounds using an expert frequency-energy based metric. *Annals of biomedical engineering*, 41(2), 279-292.
- [18] Wang, Y., Li, W., Zhou, J., Li, X., & Pu, Y. (2014). Identification of the normal and abnormal heart sounds using wavelet-time entropy features based on OMS-WPD. *Future Generation Computer Systems*, 37, 488-495.
- [19] Elgendi, M., Bobhate, P., Jain, S., Guo, L., Rutledge, J., Coe, Y., ... & Adatia, I. (2014). Spectral analysis of the heart sounds in children with and without pulmonary artery hypertension. *International journal of cardiology*, 173(1), 92-99.
- [20] Hassani, K., Bajelani, K., Navidbakhsh, M., & Doyle, J. (2014). Detection and identification of S1 and S2 heart sounds using wavelet decomposition and reconstruction. In *XIII Mediterranean Conference on Medical and Biological Engineering and Computing 2013* (pp. 1-6). IEEE.
- [1] Garcia, R. U., Aggarwal, S., & Natarajan, G. (2016). Parental perception of functional status and impact on the family of children with congenital heart surgery. *Early human development*, 96, 45-51.
- [2] Mavroudis, C. (2015). Ventricular septal defect. In *Atlas of Pediatric Cardiac Surgery* (pp. 99-115). Springer London.
- [3] Li, D., Ji, L., Liu, L., Liu, Y., Hou, H., Yu, K., & Zhao, Z. (2014). Characterization of circulating microRNA expression in patients with a ventricular septal defect. *PLoS one*, 9(8), e106318.
- [4] American Heart Association Statistical Fact Sheet, International Cardiovascular Disease Statistics, Update 2012, Available from: <http://www.heart.org/downloadable/heart/1236204012112INTL.pdf>.
- [5] World Health Organization Fact sheet N°317, Cardiovascular diseases, Updated September 2012, Available from: <http://www.who.int/mediacentre/factsheets/fs317/en/print.html>.
- [6] Javed, F., Venkatachalam, P. A., & MH, A. F. (2006). A signal processing module for the analysis of heart sounds and heart murmurs. In *Journal of Physics: Conference Series* (Vol. 34, No. 1, p. 1098). IOP Publishing.
- [7] Penny, D. J., & Vick, G. W. (2011). Ventricular septal defect. *The Lancet*, 377(9771), 1103-1112.
- [8] Rudolph, A. M. (2009). Ventricular septal defect. *Congenital Diseases of the Heart: Clinical-*

- [27] Patidar, S., Pachori, R. B., & Garg, N. (2015). Automatic diagnosis of septal defects based on tunable-Q wavelet transform of cardiac sound signals. *Expert Systems with Applications*, 42(7), 3315-3326.
- [28] Ezeiza, A., de Ipiña, K. L., Hernández, C., & Barroso, N. (2013). Enhancing the feature extraction process for automatic speech recognition with fractal dimensions. *Cognitive Computation*, 5(4), 545-550.
- [29] Xu, J., Durand, L., & Pibarot, P. (2000). Nonlinear transient chirp signal modeling of the aortic and pulmonary components of the second heart sound. *IEEE Transactions on Biomedical Engineering*, 47(10), 1328-1335.
- [30] Choi, S., & Jiang, Z. (2010). Cardiac sound murmurs classification with autoregressive spectral analysis and multi-support vector machine technique. *Computers in biology and medicine*, 40(1), 8-20.
- [31] Yan Z, Jiang Z, Miyamoto A, Wei Y. The moment segmentation analysis of heart sound pattern. *Computer methods and programs in biomedicine*. 2010;98(2):140-50.
- [32] Amit G, Gavriely N, Intrator N. Cluster analysis and classification of heart sounds. *Biomedical Signal Processing and Control*. 2009;4(1):26-36.
- 509-514).Springer International Publishing. Chicago.
- [21] Golpaygani, A. T., Abolpour, N., Hassani, K., Bajelani, K., & Doyle, D. J. (2015). Detection and identification of S1 and S2 heart sounds using wavelet decomposition method. *International Journal of Biomathematics*, 8(06), 1550078.
- [22] Shamsi, H., & Ozbek, I. Y. (2015). A robust method for online heart sound localization in respiratory sound based on temporal fuzzy c-means. *Medical & biological engineering & computing*, 53(1), 45-56.
- [23] Reed, T. R., Reed, N. E., & Fritzson, P. (2004). Heart sound analysis for symptom detection and computer-aided diagnosis. *Simulation Modelling Practice and Theory*, 12(2), 129-146.
- [24] Noponen, A. L., Lukkarinen, S., Angerla, A., & Sepponen, R. (2007). Phono-spectrographic analysis of heart murmur in children. *BMC pediatrics*, 7(1), 1.
- [25] Akbari, M. A., Hassani, K., Doyle, J. D., Navidbakhsh, M., Sangargir, M., Bajelani, K., & Ahmadi, Z. S. (2011). Digital Subtraction Phonocardiography (DSP) applied to the detection and characterization of heart murmurs. *Biomedical engineering online*, 10(1), 1.
- [26] Frank, J. E., & Jacobe, K. M. (2011). Evaluation and management of heart murmurs in children. *American family physician*, 84(7), 793.