

پیش‌بینی آریتمی قلبی در سیگنال ECG با

به کارگیری مجمعی از ماشین‌های بردار پشتیبان

چند هسته‌ای بهینه

مریم عظیمی فر^۱، صمد نجاتیان^{۲*}، حمید پروین^۳، کرم‌الله باقری فرد^۴ و وحیده رضایی^۵

^۱ و ^۴ گروه کامپیوتر، واحد یاسوج، دانشگاه آزاد اسلامی، یاسوج، ایران

^۲ گروه برق، واحد یاسوج، دانشگاه آزاد اسلامی، یاسوج، ایران

^۳ گروه کامپیوتر، واحد نورآباد ممسنی، دانشگاه آزاد اسلامی، نورآباد ممسنی، ایران

^۵ گروه ریاضی، واحد یاسوج، دانشگاه آزاد اسلامی، یاسوج، ایران

چکیده

استفاده از هوش مصنوعی در فرآیند تشخیص بیماری‌های قلبی سال‌ها مورد توجه پژوهش‌گران قرار گرفته است. در این مقاله، روشی کارآمد جهت گزینش ویژگی‌های مناسب استخراج‌شده از سیگنال‌های الکتروکاردیوگرام (ECG)، بر پایه الگوریتم ژنتیک برای استفاده در یک اجماعی از طبقه‌بندهای ماشین بردار پشتیبان (SVM) چند هسته‌ای که هر کدام از این طبقه‌بندها به وسیله یک الگوریتم ژنتیک بهینه شده‌اند، پیشنهاد شده است. پیشتر نشان داده شده که به علت خاصیت هایش (نگاشت فضای ویژگی و حداکثرسازی مرز تصمیم) طبقه‌بند ماشین بردار پشتیبان یکی از روش‌های طبقه‌بندی است که مناسب هر نوع محیطی محسوب می‌شود. این مقاله از تعدادی طبقه‌بند ماشین بردار پشتیبان چند هسته‌ای به عنوان یک طبقه‌بند ترکیبی بهره می‌گیرد. تنوع اجماع به وسیله آموزش هر طبقه‌بند ماشین بردار پشتیبان چند هسته‌ای بر روی یک زیرفضا (یعنی زیرمجموعه‌ای از ویژگی‌ها) ایجاد می‌شود. در این روش برای ترکیب خروجی طبقه‌بندها از روش رأی اکثریت استفاده شده است. از طرفی در طبقه‌بندی سیگنال‌های ECG به طور معمول از سیگنال‌ها به عنوان ویژگی‌های آن استفاده می‌شود؛ در نتیجه از آن جایی که روش‌های طبقه‌بندی سیگنال‌ها با تعداد زیادی ویژگی مواجه هستند و حذف نکردن این ویژگی‌ها مشکل ابعاد بالا را ایجاد می‌کند و همچنین بار محاسباتی را برای کاربرد مورد نظر بالا می‌برد، گام انتخاب ویژگی اجتناب‌ناپذیر است. ویژگی‌های استخراج شده شامل ویژگی‌های زمانی، AR^1 و ضرایب موجک است که تعداد این ویژگی‌ها با استفاده از الگوریتم ژنتیک بهینه خواهد شد. ارزیابی این مجموعه از ویژگی‌های انتخاب‌شده به وسیله الگوریتم ژنتیک با اعمال به یک SVM چند هسته‌ای بررسی می‌شود. از الگوریتم ژنتیک جهت بهینه‌سازی پارامترهای هر کدام از SVM-ها استفاده می‌شود. به کمک شبیه‌سازی رایانه‌ای، صحت کلی سامانه برای شناسایی شش نوع ریتم قلبی ۹۹/۱۵٪ به دست آمده است که در مقایسه دقت حاصل‌شده با پژوهش‌های پیشین، کارایی مطلوب روش پیشنهادی را نشان می‌دهد.

واژگان کلیدی: سیگنال ECG، انتخاب ویژگی، ماشین بردار پشتیبان چند هسته‌ای، اجماع طبقه‌بندی، الگوریتم ژنتیک.

Predicting cardiac arrhythmia on ECG signal using an ensemble of optimal multicore support vector machines

Maryam Azimi Far¹, Samad Nejatian^{2*}, Hamid Parvin³, Karamollah Bagherifard⁴ & Vahideh Rezaie⁵

^{1,4}Department of Computer Engineering, Yasooj Branch, Islamic Azad University, Yasooj, Iran

²Department of Electrical Engineering, Yasooj Branch, Islamic Azad University, Yasooj, Iran

³Department of Computer Engineering, Nourabad Mamasani Branch, Islamic Azad University, Nourabad, Iran

⁵Department of Mathematics, Yasooj Branch, Islamic Azad University, Yasooj, Iran

¹ Autoregressive

* Corresponding author

* نویسنده عهده‌دار مکاتبات



Abstract

The use of artificial intelligence in the process of diagnosing heart disease has been considered by researchers for many years. In this paper, an efficient method for selecting appropriate features extracted from electrocardiogram (ECG) signals, based on a genetic algorithm for use in an ensemble multi-kernel support vector machine classifiers, each of which is based on an optimized genetic algorithm is proposed. It has already been shown that due to its features (feature space mapping and decision boundary maximization), support vector machine classification is one of the classification methods that are suitable for any type of environment. This paper uses a number of multi-kernel support vector machine classifiers as an ensemble classifier. ensemble diversity is created by teaching each multi-kernel support vector machine classifier on a subspace (ie, a subset of features). In this method, the majority vote method is used to combine the output of the categories. On the other hand, in the classification of ECG signals, signals are usually used as their characteristics; As a result, since the methods of classifying signals are faced with a large number of features, and not removing these features creates a problem of high dimensions and also increases the computational for the intended application, the step of selecting the feature is inevitable. The extracted features include temporal properties, AR, and wavelet coefficients, the number of which will be optimized using a genetic algorithm. The evaluation of this set of features selected by the genetic algorithm is examined by applying it to a multivariate SVM. A genetic algorithm is used to optimize the parameters of each of the SVMs. Indicates the desired method. With the help of computer simulation, the overall accuracy of the system for identifying 6 types of heart rhythms is 99.15%, which in comparison with the accuracy obtained with previous research, shows the optimal performance of the proposed method.

Keywords: ElectroCardioGram Signals, Feature Selection, Multiple Support Vector Machine, Ensemble classification, Genetic Algorithm.

۱- مقدمه

در طول دهه‌های گذشته، حجم زیادی از داده‌های بیماران قلبی و عروقی در پایگاه داده‌های سازمان مراقبت از سلامت، مثل بیمارستان‌ها و مراکز درمانی و... ذخیره شده است. مراکز پزشکی، با مقاصد گوناگون، به جمع‌آوری این داده‌ها می‌پردازند؛ درواقع این سازمان‌ها، در اطلاعات غرق شده‌اند، درحالی‌که تشنه دانش هستند. پژوهش روی این داده‌ها و سردرگمی حاصل از آن مشکلی است که مانع رسیدن به نتایج قابل توجه می‌شود؛ چون باید از دانش درون داده‌ها به نحو مناسب استفاده کرد. درواقع داده‌کاوی، پاسخی به این نیاز سازمان‌های مراقبت از سلامت بوده است. هرچقدر که حجم داده‌ها بیشتر و روابط بین آنها نیز پیچیده‌تر باشد، دسترسی به اطلاعات نهفته درون داده‌ها نیز مشکل‌تر می‌شود؛ بنابراین نقش داده‌کاوی به‌عنوان یکی از روش‌های کشف دانش در صنعت مراقبت از سلامت و به‌ویژه در پیش‌گویی بیماری‌ها و به‌دست‌آوردن روابط مفید بین عوامل خطرزا در بیماری‌ها روشن‌تر می‌شود. از طرفی، بیماری‌های قلبی و عروقی نیز یکی از شایع‌ترین علت‌های مرگ و میر در کشورهای درحال توسعه است [1]. بیماری قلبی، یک اصطلاح کلی و شامل تمام بیماری‌هایی است که بر اثر عوامل مختلف روی قلب تأثیر می‌گذارند. بیماری کرونر قلب، بیماری التهاب عضله قلب، آنژین سینه و... جزء بیماری‌های قلبی و عروقی محسوب می‌شوند. روش‌های

مختلف داده‌کاوی می‌تواند به پیش‌گویی دقیق بیماری‌های قلبی و عروقی کمک کند و از طرفی نیز باعث کاهش هزینه‌های اضافی‌ای که برای مثال ممکن است در اثر تجویز آزمایش‌های نامربوط بالینی ایجاد می‌شود، خواهد شد. همچنین در کاهش خطای تشخیص و پیش‌گویی اثر می‌گذارد و کیفیت خدمات نیز بهبود خواهد یافت. برخی از روش‌های داده‌کاوی که برای داده‌های پزشکی به کار بسته می‌شوند عبارتند از: شبکه‌های عصبی^۱، درخت‌های تصمیم^۲، یافتن قانون انجمنی^۳، شبکه‌های بیزی، ماشین بردار پشتیبان^۴، خوشه‌بندی^۵ و...

هر کدام از این روش‌ها، بستگی به نوع کاربریشان سودمند خواهند بود؛ اما استفاده از تنها یک الگوریتم داده‌کاوی، جهت تشخیص و یا پیش‌گویی تمام بیماری‌ها کاری دشوار است. بعضی از الگوریتم‌ها برای برخی کارها بهتر از دیگری هستند، اما هنگامی که از ترکیبی از مزایای برخی الگوریتم‌ها استفاده کنیم، نتایج بهتری در کارایی خواهیم داشت که ما در این پژوهش نیز به بررسی آن می‌پردازیم تا بتوانیم بهترین نوع روش داده‌کاوی را از لحاظ کارایی‌هایی چون دقت^۶، حساسیت^۷ و ویژگی^۱ که در پیش‌گویی بیماری‌ها مرسوم هستند، معرفی کنیم.

¹ Artificial Neural Network

² Decision Trees

³ Association Rules

⁴ support vector machine

⁵ clustering

⁶ accuracy

⁷ sensitivity

نوفه باشند، بنابراین لازم است تا با یک عملیات پیش‌پردازش مناسب، نوفه حذف شود. برای حذف نوفه از تبدیل ویولت با تابع پایه db6 استفاده شده و با استفاده از آن فرکانس‌های بالا که ۴۵ تا ۱۸۰ هرتز بوده، حذف شده‌اند.

در بیشتر پژوهش‌های مختلف نشان داده شده است که اجماع همیشه بهتر از مدل‌های ساده عمل می‌کند [4-10]. در این روش از طبقه‌بندهای ماشین بردار پشتیبان چندهسته‌ای به‌عنوان طبقه‌بند پایه استفاده می‌شود و تنوع از طریق استفاده از تعدادی از ویژگی‌ها برای آموزش هر طبقه‌بند و نیز انتخاب متفاوت هسته و پارامترهای متفاوت هسته‌ها در مجمع تزیق می‌شود. در این روش برای ترکیب خروجی طبقه‌بندها از روش رأی‌گیری استفاده شده است. در این پژوهش یک الگوریتم جدید و مؤثر جهت تشخیص آریتمی‌های قلبی با استفاده از ترکیب مجمع ماشین بردار پشتیبان چندهسته‌ای، و الگوریتم ژنتیک ارائه شده است.

در این پژوهش سعی در تشخیص خودکار بیماری‌های قلبی شده که در آینده‌ای قابل پیش‌بینی سبب حذف اشتباهات انسانی در تشخیص بیماری‌ها می‌شود. هدف از انجام این پژوهش ارائه یک روش مناسب برای تشخیص خودکار پنج بیماری مهم قلبی، شامل نارسایی‌های $RBBB^2$ ، $LBBB^3$ و PVC^4 و APC^5 و P^6 است. از تحلیل تغییرات ایجادشده در شکل سیگنال نرمال ECG می‌توان برای تشخیص بسیاری از انواع آریتمی و بیماری‌های قلبی استفاده شود. سیگنال ECG می‌تواند به بخش‌ها و فواصل زمانی گوناگون تقسیم شود که با تعیین محدوده برای این بخش‌ها، ضربان‌های غیرنرمال تشخیص داده شوند. سیگنال‌های ECG با توجه به‌شکل آن‌ها و نوع آریتمی‌ها به گروه‌های مختلف تقسیم می‌شوند. انواع ضربان‌های قلبی با توجه به پایگاه داده MIT-BIH در جدول (۱) نشان داده شده‌اند [11-12].

در این پژوهش به طبقه‌بندی شش شکل مختلف سیگنال ECG که دارای بیشترین اهمیت هستند، پرداخته شده است. این ضربان‌ها عبارتند از [12]:

² Right bundle branch block

³ Left bundle branch block

⁴ Ventricular premature beat

⁵ Atrial premature beat

⁶ Pace beat

تشخیص درست و به‌موقع آریتمی‌های قلبی از اهمیت به‌سزایی برخوردار است. یکی از راه‌های شناخته‌شده برای تشخیص به‌موقع این آریتمی‌ها بررسی فعالیت‌های الکتریکی قلب با استفاده از سیگنال‌های الکتروکاردیوگرافی یا به‌اختصار ECG است. تغییرات معنی‌داری از ساختار قلب بیماران و ضربان‌های آن با استفاده از این سیگنال‌ها قابل تشخیص هستند [1]. در چندین سال اخیر، طبقه‌بندی خودکار سیگنال‌های ECG توجه زیاد مهندسان پزشکی را به‌خود جلب کرده است. به‌واسطه این سیگنال‌ها یک متخصص قلب اطلاعاتی مفید درباره ریتم و عملکرد قلب خواهد داشت؛ بنابراین آنالیز آن نشان‌دهنده یک راه مؤثر برای شناسایی و درمان انواع بیماری‌های قلبی است [2].


برای طراحی یک سامانه هوشمند تشخیص آریتمی‌های قلبی از روی سیگنال‌های ECG، لازم است ابتدا ویژگی‌های مناسبی از روی این سیگنال‌ها استخراج شود. با توجه به اینکه ضرایب موجک قادرند اطلاعات زمان-فرکانس سیگنال را به‌طور توأم توصیف کنند، یکی از انتخاب‌ها برای استخراج ویژگی از یک سیگنال ECG خواهد بود. در این راستا باید تعداد سطوح تجزیه و نوع موجک مشخص شوند. همچنین، نتایج پژوهش‌های قلبی نشان داده است که برای استخراج ویژگی از سیگنال‌های ECG خانواده دایلیچز و هار در مقایسه با سایر موجک‌ها بسیار مناسب‌تر هستند [3]. تشخیص پزشک براساس اطلاعات زمانی و ریخت‌شناسی استخراج‌شده از سیگنال ECG است. درحالی‌که گاهی‌اوقات تحلیل موجک بر روی سیگنال‌های قلبی به‌تنهایی برای طبقه‌بندی کافی نیست و به‌همین دلیل استفاده از دیگر مشخصه‌های موجود در سیگنال‌های قلبی برای طبقه‌بندی بیماری‌های قلبی ضروری است. برای توصیف کامل‌تر سیگنال‌های ECG علاوه‌بر ویژگی‌های موجک از ویژگی‌های زمانی نیز استفاده می‌شود [3].

در این پژوهش از مجمعی از ماشین‌های بردار پشتیبان به‌همراه الگوریتم ژنتیک سعی شده تا آریتمی‌های قلبی با دقت بالایی پیش‌بینی شود. نخستین قدم در طراحی یک مدل داده‌کاوی، عملیات پیش‌پردازش است. از آن‌جایی‌که ممکن است، سیگنال‌های ECG دارای

⁸ specificity

نرمال (N)، بلوک شاخه دسته‌ای چپ (L یا LBBB)، بلوک شاخه دسته‌ای راست (R یا RBBB)، انقباض زودرس بطنی (V یا PVC)، ضربان زودرس دهلیزی (A) و تپش قلب (Pace beat).

ترکیبی از مجمع ماشین‌های بردار پشتیبان چندهسته‌ای و بهینه‌کردن پارامترهای ورودی SVMs توسط الگوریتم ژنتیک برای پیش‌بینی آریتمی‌های قلبی تا به حال ارائه نشده است. در این روش همچنین برای انتخاب ویژگی، از ترکیب ضریب همبستگی و الگوریتم ژنتیک، برای افزایش دقت طبقه‌بندی نهایی استفاده شده است. سیگنال ECG در طول هر دوره کاری قلب، دارای منحنی مشخصه‌ای به صورت شکل (۱) است.



(شکل-۱): یک سیکل از سیگنال ECG [13].

(Figure-1): A cycle of the ECG signal [13].

(جدول-۱): ضربان های قلبی [3]

(Table-1): Heart Rate [3]

Label	Beat type
N	Normal beat
L	Left bundle branch block
R	Right bundle branch block
A	Atrial premature beat
A	Abberated atrial premature beat
J	Nodal(junctional) premature beat
S	Supraventricular premature beat
V	Ventricular premature beat
F	Fusion of ventricular and normal beat
b or I	Ventricular flutter beat
J	Nodal(junctional) escape beat
E	Ventricular escape beat
F	Fusion of paced and normal beat

۲- ادبیات پژوهش و کارهای مرتبط

پیشین

هوشمندسازی فرآیند تشخیص بیماری‌های قلبی سال‌ها است مورد بحث پژوهش‌گران تمامی کشورها قرار گرفته است. این فرآیند شامل مراحل است که طی آن سیگنال ECG به عنوان ورودی نرم‌افزار انتخاب می‌شود و انتظار این

است که نرم‌افزار با دقت قابل قبولی سلامت یا بیماری و حتی نوع بیماری قلبی را تشخیص دهد. تمامی این نرم‌افزارها پس از دریافت سیگنال، ویژگی‌های مناسب آن را استخراج و انتخاب کرده است؛ سپس به تشخیص نوع بیماری می‌پردازد. در هر یک از مراحل بیان‌شده روش‌های گوناگونی وجود دارد که در این بخش به پژوهش‌های پیشین و روشی که مورد استفاده قرار گرفته است، پرداخته خواهد شد. در این بخش ابتدا موضوعات مرتبط با روش پیشنهادی مقاله مورد بحث و بررسی قرار گرفته و در ادامه کارهای گذشته مرتبط با پژوهش آورده می‌شود.

۲-۲- استراتژی انتخاب ویژگی

انتخاب ویژگی فرآیندی است که ویژگی‌های با قدرت تشخیص بالاتر و مؤثرتر را از مجموعه‌های داده برای انجام اعمال داده‌کاوی انتخاب می‌کند.

الگوریتم‌های انتخاب ویژگی به طور کلی به سه دسته تقسیم می‌شوند: مدل‌های فیلتر، مدل‌های رپر^۱ (پوششی) و مدل‌های ترکیبی [15]. مدل‌های فیلتر از مشخصات ذاتی یا آماری ویژگی‌های مجموعه‌های داده استفاده می‌کنند و از هر گونه الگوریتم یادگیری مستقل‌اند. چنین رویه‌هایی شامل ماشین یادگیری نیستند و برای مجموعه‌داده‌های با ابعاد بالا مؤثر بوده و پیشنهاد می‌شوند. در مقابل مدل‌های رپر از ماشین‌های یادگیری استفاده کرده و زیرمجموعه ویژگی‌ها را بر اساس تخمین کارایی انتخاب می‌کنند. در مقایسه با فیلترها رپر دارای زمان و هزینه‌های محاسباتی بالاتری بوده و برای مجموعه‌داده‌های با ابعاد بالا مناسب نیست. مزیت اصلی رپر در دقت بالای پیش‌بینی آن‌ها است. نتایج جستجوی رپر برای یافتن بهترین زیرمجموعه ویژگی بسیار بالاتر از فیلترها گزارش شده است. برای انتخاب ویژگی خوب، تلاش اصلی فرایند جستجو باید شناخت ویژگی‌های مؤثر و غیرافزونه باشد [15]. اغلب روش‌های ترکیبی فیلتر و رپر، از فیلترها جهت رتبه‌بندی ویژگی‌ها و کاهش تعداد ویژگی‌های نامزد استفاده می‌کنند. به طور کلی مدل‌های ترکیبی بر اساس رویه‌های ترتیبی دو مرحله‌ای کار می‌کنند. در مرحله نخست به طور معمول براساس فیلترها تعداد ویژگی‌های مورد نظر برای مرحله دوم کاهش می‌یابند، سپس با استفاده از مجموعه کاهش‌یافته یک رویه رپر در مرحله دوم جهت انتخاب ویژگی‌های مطلوب اعمال می‌شود.

¹ Wrapper

(جدول-۲): ویژگی و یولت برای تشخیص مولفه‌های شناختی از

[14] ECG

(Table-2): Violet Characteristics for Recognizing Cognitive Components of ECG [6]

ویژگی‌های موجک استخراج شده
انرژی
درصد انرژی طول سیگنال
واریانس ضرایب و یولت
انحراف معیار ضرایب و یولت
مقدار حداکثر توزیع داده‌ها
انحراف داده‌ها
انحراف استاندارد
میانگین داده‌ها

استفاده از دیگر مشخصه‌های موجود در سیگنال‌های قلبی به‌جهت طبقه‌بندی بیماری‌های قلبی ضروری به‌نظر می‌رسد. برای توصیف کامل‌تر سیگنال ECG، علاوه‌بر ویژگی‌های موجک از ویژگی‌های زمانی نیز در این پژوهش استفاده شده است. ویژگی‌های زمانی مورد استفاده شامل ۹ ویژگی زمانی برای تشخیص مولفه‌های شناختی از سیگنال ECG هستند که نماد اختصاری آن‌ها در جدول (۳) بیان شده است [19].

۲-۳- مروری بر کارهای گذشته

در این بخش ابتدا مروری بر روش‌های استخراج ویژگی صورت گرفته و سپس روش‌های هوشمندی که برای تشخیص آریتمی‌های قلبی توسط سایر پژوهش‌گران انجام گرفته، مورد بحث و بررسی قرار می‌گیرد.

در این بخش ابتدا به تشریح روش‌های استخراج ویژگی از جمله روش تحلیل مولفه‌های اصلی^۱ پرداخته می‌شود. در روش تحلیل مولفه‌های اصلی، محورهای مختصات جدیدی برای داده‌ها تعریف می‌شود؛ به‌گونه‌ای که نخستین محور در جهتی قرار می‌گیرد که واریانس داده‌ها بیشینه است و دومین محور نیز عمود بر محور نخست و در جهتی که واریانس داده‌ها بیشینه باشد، در نظر گرفته می‌شود و به‌همین ترتیب، محورهای بعدی عمود بر تمامی محورهای قبلی به‌گونه‌ای قرار می‌گیرند که واریانس داده‌ها در آن جهت بیشینه باشد [20]. پژوهش‌گر مرجع [21] یک مطالعه مقایسه‌ای بین استفاده از PCA و ICA برای کاهش نوفه و مصنوعات سیگنال ECG ارائه داده است. نتایج این مقاله نشان داد که، PCA یک روش بهتری برای کاهش نوفه است، در حالی‌که ICA برای استخراج ویژگی‌ها می‌تواند بهتر باشد. روش ICA منابع جداگانه‌ای را از یک سیگنال نوفه‌ای مجزا می‌سازد. ECG ترکیبی از چندین پتانسیل عمل است و هر یک از این اقدامات می‌تواند به‌شدت با یک طبقه آریتمی مرتبط باشد. به‌عنوان منابع نوفه‌ای، راه‌کار PCA منابع را با توجه به سهم انرژی در سیگنال جدا می‌کند. مطالعه ارائه‌شده در [21] نشان می‌دهد که منابع نوفه‌ای انرژی کمی دارند و جداسازی آن‌ها دشوار است و این‌که منابع جداشده به‌وسیله ICA ویژگی‌های امیدوارکننده‌ای برای طبقه‌بندی ECG هستند؛ علاوه‌بر این، نشان داده شده است که ترکیبی از راه‌کارهای اولیه، یعنی PCA برای کاهش نوفه و

۱-۲-۲- ویژگی‌های استخراج شده از یولت

با توجه به این‌که ضرایب موجک (DWT) قادرند اطلاعات زمان-فرکانس سیگنال را به‌طور توأم توصیف کنند، یکی از انتخاب‌ها برای استخراج ویژگی از یک سیگنال الکتروکاردیوگرافی خواهد بود. در این راستا باید تعداد سطوح تجزیه و نوع موجک مشخص شوند. برای توصیف کامل‌تر سیگنال‌های ECG علاوه‌بر ویژگی‌های موجک از ویژگی‌های زمانی نیز استفاده می‌شود. استفاده از پارامترهای جدول (۲) به‌جای استفاده از ضرایب و یولت توصیه شده است [14 - 18].

(جدول-۳): ویژگی زمانی برای تشخیص مولفه‌های

شناختی از ECG

(Table-3): Timing feature for diagnosing cognitive components of ECG

ویژگی	نماد اختصاری
دامنه بیشینه سیگنال	AMP
دامنه کمینه سیگنال	-AMP
ناحیه مثبت	PAR
ناحیه منفی	NAR
قدر مطلق ناحیه منفی	NANR
مجموع ناحیه	TAR
قدر مطلق مجموع ناحیه	ATAR
قدر مطلق مجموع ناحیه	TAAR
پیک تا پیک سیگنال	PP

۲-۲-۲- ویژگی زمانی

تشخیص پزشک به‌طور عمده مبتنی بر اطلاعات زمانی و ریخت‌شناسی استخراج‌شده از سیگنال الکتروکاردیوگرافی است. این در حالی است که در برخی از شرایط ویژگی‌های به‌دست‌آمده از تحلیل موجک بر روی سیگنال‌های قلبی، به‌تنهایی تمایز کافی برای طبقه‌بندی ندارند؛ از این‌رو،

¹ Principal Component Analysis


ICA برای استخراج ویژگی، می‌تواند مزایای بیشتری را نسبت به حالت تکی آن‌ها داشته باشد. روش دیگر مبتنی بر PCA با عنوان، تجزیه و تحلیل مؤلفه اصلی هسته (KPCA) [22] انجام گرفته است. در این کار، مقایسه‌ای بین PCA و KPCA انجام شد و نتیجه گرفته شد که KPCA از روش PCA برای طبقه‌بندی سیگنال ECG بهتر عمل می‌کند. به گفته نویسندگان مرجع [22] KPCA به دلیل ساختار غیرخطی، عملکرد بهتری دارد. زمانی که مجموعه‌ای از ویژگی‌های ضربان قلب به عنوان ورودی استخراج شود، می‌توان مدل‌هایی را با استفاده از الگوریتم‌های هوش مصنوعی از حوزه‌های یادگیری ماشین و حوزه داده‌کاوی [22 – 24] برای طبقه‌بندی آریتمی ضربان قلب ایجاد کرد. سه الگوریتم محبوب مورد استفاده برای این کار عبارتند از: ماشین‌های بردار پشتیبان (SVM) [25–30]، شبکه‌های عصبی مصنوعی (ANN) و رگرسیون لجستیک (RL).

SVM یکی از محبوب‌ترین طبقه‌بندهایی است که در روش‌های پژوهشی برای طبقه‌بندی آریتمی مبتنی بر ECG زیاد یافت می‌شود. نویسنده مرجع [31] از SVM استفاده کرد و براساس استاندارد طبقه‌ای AAMI و طرح تقسیم مجموعه داده‌ها که توسط نویسندگان [32] ارائه شده است، اعتبارسنجی کرد. همین نویسندگان از SVM در یک پیکربندی سلسله‌مراتبی برای رفع عدم تعادل از بانک اطلاعاتی MIT – BIH استفاده کرده و مقادیر امیدوارکننده‌ای را گزارش کردند. نویسنده مرجع [33] موفق به غلبه بر عدم تعادل MIT-BIH database با SVM شد، و مقادیر متفاوتی را برای هر طبقه به دست آورد. سود حاصل شده برای طبقه‌های SVEB و F در پژوهش یادشده گزارش شده است. رویکردهای طبقه‌بندی مختلف دیگری نیز با تغییرات SVM در [34–36] مطرح شده‌اند. از جمله، ترکیبی از تئوری فازی برای پالایش طبقه‌بندی SVM [34]، همراه با یک مجموعه از طبقه‌بندهای دیگر [34]، الگوریتم ژنتیک همراه با SVM محدود فازی [35] و کمینه مربعات SVM [36]. نویسندگان مرجع [34] از SVM به صورت سلسله‌مراتبی با پیشینه سازوکار رأی‌دهی و گزارش بهبود چشم‌گیر استفاده کرد. نویسندگان مرجع [37] استفاده یک تابع هسته جدید را برای SVM پیشنهاد کردند. در این کار، برای مقایسه نتایج به دست آمده از یک SVM و یک شبکه عصبی مصنوعی چندلایه پس‌انتشار استفاده شد. این در حالی است که، SVM در زمان اجرا مؤثرتر بود، اما هم در آموزش و هم در آزمایش، شبکه عصبی مصنوعی چندلایه

پس‌انتشار، از نظر دقت، حساسیت (Se)، پیش‌بینی مثبت (+P) و نرخ مثبت کاذب (FPR) بهتر عمل می‌کرد. از آنجایی که SVM یک رفتار منفی برای طبقه‌های نامتوازن ارائه می‌دهد، روش‌های متوازن‌سازی مجموعه داده برای مرحله آموزش، که برای این مشکل اندکی مورد بررسی قرار می‌گیرند، می‌توانند در پژوهش‌های آینده مورد مطالعه قرار گیرند. به عنوان مثال، روش‌های نمونه‌گیری پیشرفته‌تر، یعنی روش SMOTE [37]. طبقه‌بندی سیگنال ECG با طبقه‌بند ماشین بردار پشتیبان و الگوریتم PSO مرجع [38] ارائه شده است. در این پژوهش از ویژگی‌های زمانی و مورفولوژیک استفاده شده است. آزمایش از روش‌های طبقه‌بند RBF و KNN و SVM به عمل آمده که نتایج برتری طبقه‌بند SVM با هسته گوسی را نشان می‌دهد. همچنین برای تنظیم پارامترهای SVM از الگوریتم بهینه‌ساز PSO استفاده شده است که باعث بهبود عملکرد طبقه‌بند SVM می‌شود. در این مقاله از ۲۵۰، ۵۰۰ و ۷۵۰ ضربان برای آموزش استفاده شده که با توجه به نتایج آزمایش عملکرد طبقه‌بند با ۷۵۰ داده آموزش دارای دقت ۹۳.۲۷٪ است. روشی برای طبقه‌بندی آریتمی‌های قلبی با استفاده از PSO، در مرجع [39] ارائه شده است. در این مقاله یک سامانه جدید برای طبقه‌بندی سه نوع ضربان قلب شامل ضربان نرمال و دو آریتمی قلبی ارائه شده است. این سامانه شامل سه ماژول اصلی، یک ماژول استخراج ویژگی، یک ماژول طبقه‌بندی و یک ماژول بهینه‌سازی است. در ماژول استخراج ویژگی ترکیبی مناسب از ویژگی‌های شکلی و زمانی ایجاد می‌شود. در ماژول طبقه‌بندی یک طبقه‌بند بر پایه ماشین بردار پشتیبان ارائه شده است. در ماژول بهینه‌سازی از الگوریتم اجتماع ذرات برای یافتن بهترین ویژگی‌ها استفاده شده است. نتایج شبیه‌سازی دقت مناسبی داشت و این در حالی است که در به دست آمدن این سطح دقت، فقط مقدار کمی از ویژگی‌ها استفاده شده است. طبقه‌بندی سیگنال ECG با استفاده از خواص مورفولوژی در مرجع [40] ارائه شده است. در این پژوهش برای طبقه‌بندی ضربان از یک مجموعه داده بزرگ با آموزش شبکه عصبی، استفاده از مویک و ویژگی‌های زمانی استفاده شده است. آن‌ها دریافتند که مقیاس چهارم از تبدیل ویولت دوتایی با ویولت مرتبه دوم همراه با نرخ فاصله قبل و بعد از R – R در تمایز نرمال و PVC دیگر ضربان‌ها بسیار مؤثر است. نویسندگان در مرجع [41] بر اساس شبکه عصبی برای روشی را با عنوان طبقه‌بندی خودکار سیگنال ECG برای تشخیص بیماری‌های قلبی با به کارگیری ویژگی‌های

طبقه که شامل سیگنال نرمال و پنج آریتمی قلبی که از گروهی خاص از سیگنال ECG بیماران پایگاه داده - MIT BIH انجام داده است. طبقه‌بندی سیگنال ECG با استفاده از تبدیل موجک و شبکه عصبی فازی در مرجع [43] ارائه شده است. این مقاله یک روش جدید، یعنی مجمعی از شبکه‌های عصبی کانولوشنال قابل جداسازی عمیق (DSC) را برای طبقه‌بندی ضربان‌های ECG آریتمی قلبی پیشنهاد می‌کند. با استفاده از این روش، چهار مرحله طبقه‌بندی ECG، یعنی تشخیص QRS، پیش‌پردازش، استخراج ویژگی و طبقه‌بندی، تنها به دو مرحله، یعنی تشخیص و طبقه‌بندی QRS کاهش یافت.

مورفولوژیکی، ارائه کرده‌اند. در این روش، از شبکه عصبی احتمالی (PNN) برای مدل‌سازی و به‌دست‌آوردن توزیع بردارهای ویژگی برای طبقه‌بندی استفاده شده است. روش پیشنهادی در این مقاله طبقه‌بندی سیگنال ECG را با دقت ۹۶.۵٪ تشخیص می‌دهد. طبقه‌بندی سیگنال ECG با استفاده از موجک و شبکه عصبی در مرجع [42] ارائه شده است. در این روش، پس از چند مرحله پیش‌پردازش از تبدیل موجک پیوسته برای استخراج ویژگی‌های سیگنال می‌شود. به دلیل زیادبودن تعداد بردارهای استخراج‌شده به وسیله موجک از آنالیز PCA جهت کاهش ابعاد و به عبارتی انتخاب بهترین نمونه‌ها استفاده شده است. شبکه عصبی چندلایه، طبقه‌بندی را بر روی شش



(شکل ۲): ترتیب اجرای الگوریتم‌ها و فنون به‌کار رفته در روش پیشنهادی
(Figure-2): Trend of the algorithms and techniques used in the proposed method

الکتروکاردیوگرافی تغییر کند و در نتیجه، استخراج ویژگی‌های زمانی سیگنال با مشکل مواجه شود.

۳-۱-۲- حذف نوفه ناشی از نفس کشیدن


نوفه ناشی از نفس کشیدن که در هنگام ثبت سیگنال الکتروکاردیوگرافی ناشی می‌شود. این نوفه فرکانس پایین و در حدود پانزده هرتز است. این نوفه باعث می‌شود خط زمینه سیگنال الکتروکاردیوگرافی تغییر کند و در نتیجه، استخراج ویژگی‌های زمانی سیگنال با مشکل مواجه شود. موجک سطح هشت سیگنال ECG دارای بیشترین دامنه نسبت به سطوح موجک قبلی بوده و با حذف این سطح، اگر سیگنال ECG در بعضی ضربان‌ها دارای اختلاف قابل ملاحظه نسبت به خط زمینه باشد، اصلاح شده و سیگنال یک‌دست و منظم حاصل می‌شود. شکل (۳) سیگنال‌های ECG را نشان می‌دهد که نوفه ناشی از نفس کشیدن در آن‌ها حذف شده است.

۳- روش پیشنهادی


در این بخش به تشریح مراحل مختلف اجرای روش پیشنهادی پرداخته و همچنین تأثیر تغییر پارامترهای مؤثر در اجرای این روش، بررسی خواهد شد. در این روش، ابتدا به توضیح مراحل پیش‌پردازش سیگنال، سپس مراحل مربوط به استخراج و انتخاب ویژگی‌ها و در نهایت طبقه‌بندی داده‌ها برای طبقه‌بندی سیگنال نرمال و پنج آریتمی پرداخته می‌شود. ترتیب اجرای الگوریتم‌ها و فنون به‌کاررفته در روش پیشنهادی در شکل (۲) نشان داده شده است.

۳-۱- پیش‌پردازش

نخستین قدم پیش‌پردازش سیگنال‌ها بوده که باید بخش‌هایی را که شامل هر طبقه است جدا کرده و سپس موج هر بخش را به‌دست آوریم و نویز را از موج حذف کنیم. نوفه باعث می‌شود خط زمینه سیگنال



(شکل-۳): حذف نوفه ناشی از نفس کشیدن در ۳ سیگنال ECG
(Figure-3): Breathing noise elimination in two ECG signals




(شکل-۴): یادگیری دامنه نوفه خطوط برق در یک زمینه طبیعی. (A) خط سبز رنگ سیگنال اصلی است و خط آبی رنگ سیگنال بازسازی شده پس از حذف نوفه شهری. (B) خط سبز نشان دهنده طیف قدرت سیگنال اصلی و آبی نشان دهنده سیگنال بازسازی شده است. (C) این فرایندی را نشان می دهد که دامنه نوفه به وسیله الگوریتم یاد گرفته می شود.

(Figure-4): Learning the amplitude of power line noise in a natural context. (A) The green line is the original signal and the blue line is the reconstructed signal after removing the urban noise. (B) The green line represents the power signal spectrum and the blue line represents the reconstructed signal. (C) indicates the process by which the noise amplitude is learned by the algorithm

۳-۱-۳- حذف نوفه ناشی از برق شهر

سیگنال ECG در این مرحله دارای نوفه ناشی از برق شهر است. برای حذف نوفه از تبدیل ویولت با تابع پایه db6 استفاده شده و با استفاده از آن فرکانس های بالا که ۴۵ تا ۱۸۰ هرتز بوده، حذف شده است. این حذف نوفه با حذف ضرایب cd1 و cd2 تبدیل ویولت انجام شده است. تعداد داده های طبقه N شامل ۸۵۰۵۲ داده، طبقه S شامل ۲۴۵۰، طبقه F شامل ۹۸۲، طبقه V شامل ۷۵۷۳ و طبقه U شامل ۷۷۸۵ داده بوده است. شکل (۶) سیگنال ECG را



(شکل-۵): A: سیگنال ECG 104 همراه داده های پرت
B: سیگنال ECG 104 پس از حذف داده های پرت
(Figure-5): A: 104 ECG signal with outbound data
B: 104 ECG signal after deleting outbound data

نشان می‌دهد که در دو حالت نوفه‌ای و بدون نوفه ارائه شده است. در این شکل خط سبز رنگ سیگنال اصلی است و خط آبی رنگ سیگنال بازسازی شده پس از حذف نوفه شهری است. همان‌گونه که در شکل (۵) مشاهده می‌شود، روش پیشنهادی قبل و بعد از نوفه در شکل A آورده شده است. همچنین طیف قدرت سیگنال قبل و بعد از بازسازی در شکل B مشاهده می‌شود. در شکل (۵) قسمت C روند یادگیری دامنه نوفه با حذف ضرایبی از ویولت نشان داده شده است.

۳-۱-۴- مدل آمیخته گوسی و حذف ضربان‌های پرت

هر مدل آمیخته مدلی آماری است که جمعیتی از مشاهده‌ها را به صورت تعدادی زیرجمعیت بازنمایی می‌کند. پس از ایجاد یک مدل آمیخته روی یک مجموعه از مشاهده‌ها دیگر با تک‌تک مشاهده‌ها سر و کار نداریم، بلکه تعدادی زیرجمعیت داریم که هر کدام نماینده تعدادی از مشاهده‌های اولیه است. شاید توزیع آمیخته نام مناسب‌تری باشد چرا که به‌طور معمول برای بازنمایی هر زیرجمعیت از یک توزیع آماری استفاده می‌شود. در واقع هر توزیع ویژگی‌های یک زیرجمعیت را بازنمایی می‌کند، بدون آنکه به توصیف جز به جز جمعیت و تک‌تک مشاهدات بپردازد. مدل آمیخته گوسی نوع خاصی از مدل‌های آمیخته است که در آن هر زیرجمعیت با یک توزیع گوسی بازنمایی می‌شود. به‌طور کلی تابع توزیع چگالی احتمال گوسی یک متغیر تصادفی اسکالر به صورت رابطه (۱) است:

$$p(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-0.5(\frac{x-\mu}{\sigma})^2} = N(\mu, \sigma)^2 \quad (1)$$

شکل توسعه‌یافته این رابطه برای بردار تصادفی مانند x به صورت زیر است:

$$p(x) = \frac{1}{D^{1/2} \sqrt{2\pi} |\Sigma|^{1/2}} e^{-0.5(x-\mu)^T \Sigma^{-1}(x-\mu)} \quad (2)$$

که در این رابطه x بردار تصادفی، μ بردار میانگین متغیرهای تصادفی و Σ ماتریس کوواریانس متغیرهای تصادفی است. انگیزه استفاده از GMM این فرضیه بود که ضربان قلب طبیعی ECG می‌تواند به تراکم M Gaussian با ابعاد K برای هر گوسی مدل شود. الگوریتم

بیشینه‌سازی انتظار (EM) برای ساخت GMM استفاده می‌شود. یک روش تکرارشونده (iterative) است که به دنبال یافتن برآوردی با بیشترین درست‌نمایی برای پارامترهای یک توزیع پارامتری است. این الگوریتم روش متداول برای زمان‌هایی است که برخی از متغیرهای تصادفی پنهان هستند. EM تمام نمونه‌های آموزشی را در نظر می‌گیرد و سعی می‌کند تا یک توزیع گاوسی را در آن جای دهد. پس از به‌دست‌آوردن مدل‌های گاوسی از داده‌های آموزش، ارزیابی بر اساس اندازه‌گیری احتمال ورود به سیستم انجام شد. بعضی از ضربان‌ها دارای نوساناتی هستند که می‌تواند ناشی از برخی از انواع اعوجاج‌های معمول در سیگنال ECG از قبیل انقباض عضلانی، اتصال الکترود، حرکت الکترود، جابه‌جایی بیمار و غیره باشد. این ضربان‌ها در واقع داده‌های پرت هستند و استفاده از آن‌ها در ادامه کار باعث کاهش صحت طبقه‌بندی خواهد شد. بدین منظور با استفاده از مدل آمیخته گوسی با امید ریاضی بیشینه‌سازی انتظار به شناسایی و حذف این ضربان‌ها پرداختیم. شکل (۵) ضربان‌های باقی مانده پس از اعمال مدل آمیخته گوسی را نشان می‌دهد. ضربان‌های باقی‌مانده با توجه به نوع بیماری در طبقه مربوط به خود قرار می‌گیرد. در نتیجه طبقه‌هایی تولید می‌شود که در آن‌ها ضربان‌های منتخب مربوط به هر بیماری قرار دارد.

۲-۳- قطعه‌بندی سیگنال

در این مقاله، ECG ضبط‌شده در ۲۵۰ هرتز نمونه‌برداری شده و سپس به عنوان یک سیگنال دیجیتال ارائه شده است. برای این مطالعه، هر نمونه ECG به بخش‌هایی به طول هفتصد نقطه داده تقسیم شده است که پنجاه نقطه داده با بخش قبلی و بعدی هم‌پوشانی دارد. در بسیاری از کاربردهای پردازش سیگنال، مانند آنالیز سیگنال ECG، اغلب نیاز است که سیگنال به بخش‌های کوچکتر تقسیم شود. این عمل با یافتن مرزهای سیگنال در لحظات زمانی تغییر مشخصات آماری آن، از قبیل دامنه یا فرکانس، انجام می‌شود. از آن‌جا که ویژگی آماری ECG با زمان تغییر می‌کند، بنابراین سیگنال‌های ECG به عنوان سیگنال‌های غیرثابت در نظر گرفته می‌شوند. تجزیه و تحلیل سیگنال ثابت نسبت به سیگنال غیرثابت آسان‌تر است. تقسیم سیگنال به عنوان مرحله پیش‌پردازش برای تجزیه و تحلیل سیگنال غیرثابت استفاده می‌شود.

یک تقسیم‌بندی اعداد صحیح $\{1, 2, \dots, T\}$ یک دنباله‌ای از $t = \{t_0, t_1, \dots, t_k\}$ است، به‌طوری‌که:

فواصل اعداد صحیح $0 = t_0, t_1, \dots, t_{k-1} < t_k = T$ که قطعه $[t_0 + 1, t_1], \dots, [t_{k-1} + 1, t_k]$ و $[t_1 + 1, t_2], \dots, [t_0 + 1, t_1]$ نامیده می‌شود و همچنین زمان‌های $t_0, t_1, \dots, t_k$ به نقاط تغییر قطعه گفته می‌شود، به‌طوری‌که K تعداد قطعات است. در بسیاری از برنامه‌ها سری زمانی $x_1, x_2, \dots, x_T$ داده می‌شود و ما به دنبال تقسیم $\{1, 2, \dots, T\}$ هستیم که مطابق با تغییرات رفتار $x_1, x_2, \dots, x_T$ است و بنابراین قطعه‌بندی می‌تواند به عنوان یک مسأله بهینه‌سازی در نظر گرفته شود؛ به‌طوری‌که تابع هزینه قطعه‌بندی $J(t)$ می‌تواند به شرح زیر تنظیم شود:


$$J(t) = \sum_{k=1} d_{t_{k-1}} + 1, t_k \quad (3)$$

در رابطه بالا $d_{s,t}$ برای $0 < s < t < T$ خطای قطعه مربوط به بخش $[s, t]$ است. قطعه‌بندی بهینه، با عنوان $t' = t'_1, t'_2, \dots, t'_k$ نشان داده می‌شود.

$$t' = \operatorname{argmin}_{t \in T} (J(t)) \quad (4)$$

خطای قطعه $d_{s,t}$ به داده $x_1, x_2, \dots, x_T$ بستگی دارد. بخش‌های مختلف یک سیگنال ECG از نظر فیزیولوژیکی متفاوت و زمان و مدت هر قطعه دارای اهمیت تشخیصی و بیوفیزیکی است. این مسأله که شکل ECG در بیماران متغیر بوده، مشکل را دو چندان کرده است. این بدان معنا است که، تعداد قله‌ها و طول فواصل در RR و QT (از آغاز کمپلکس QRS که نشان‌دهنده دپلاریزاسیون بطن تا پایان موج T که نشان‌دهنده رپلاریزاسیون بطن) و غیره در افراد مختلف، متغیر هستند.

قطعه‌بندی ECG روشی برای یافتن امواج مختلف مانند موج P، کمپلکس QRS، امواج S و غیره موجود در آن است. از آن‌جاکه این یک فیلتر بالاگذر است، عملکرد مشتق ویژگی‌های فرکانس بالاتر، مشخصه QRS را تقویت می‌کند و فرکانس‌های پایین، امواج P و T را ضعیف می‌کند. تجزیه و تحلیل ECG شامل تشخیص QRS، امواج P و T و به دنبال آن تجزیه و تحلیل شکل‌ها، دامنه‌ها، موقعیت‌های نسبی و غیره است (شکل ۶). به تشخیص مجموعه‌های اضافه‌شده و مجموعه‌های QR کمپلکس‌های QRS و امواج P و T همچنین قطعه‌بندی یا ترسیم سیگنال ECG گفته می‌شود.



(شکل-۶): نمونه‌ای از قطعه‌بندی سیگنال ECG. رنگ زرد مربوط به امواج P، قرمز به مجتمع‌های QRS، سبز به امواج T است. علامت < به معنای شروع موج است، o به معنای قله موج است، > مربوط به جابجایی موج است.

(Figure-6): An example of medical segmentation. Yellow color corresponds to P waves, red to QRS complexes, green to T waves. The symbol < means the onset of a wave, o means the wave peak, > corresponds to the offset of a wave.

۳-۳-۳ ویژگی‌های سیگنال

پس از مرحله پیش‌پردازش از سیگنال، ویژگی‌ها استخراج می‌شوند.

۳-۳-۳-۱ استخراج ویژگی

ویژگی‌های زمانی، ویژگی‌های موجک و ویژگی‌های AR جهت مرحله استخراج ویژگی انتخاب شده و این ویژگی‌ها برای داده‌های آموزش و آزمون استخراج شده‌اند.


۳-۳-۳-۲ ویژگی‌های خطی

برای استخراج ویژگی‌های خطی از تبدیل ویولت گسسته با تابع پایه db6 استفاده شده است. با این تبدیل، ضرایب cd3 و cd4 به دست آورده می‌شوند.

۳-۳-۳-۳ ویژگی‌های غیر خطی

برای استخراج ویژگی‌های غیر خطی از higher order spectra یا HOS استفاده شده است. برای این کار از ابزار hosa موجود در تارنمای

تابع هسته‌ای ادغام‌شده بین دو داده آموزشی x_i و x_j و $k(x_i, x_j) = \sum m, \beta_m k^{(m)} = (x_i^{(m)}, x_j^{(m)})$ را به‌عنوان تابع هسته‌ای ادغام‌شده بین داده آموزشی x_i و داده آزمایشی x در نظر بگیریم، آن‌گاه می‌توان ماشین بردار پشتیبان چند هسته‌ای را به‌وسیله ماشین بردار تک‌هسته‌ای پیاده‌سازی کرد. در روابط بالا این محدودیت وجود دارد که $\sum m \beta_m = 1$ باشد. می‌توان با قراردادن مقادیر مختلف برای هر β_m و در نظر گرفتن محدودیت یادشده و با استفاده از اعتبارسنجی k -تکه‌ای روی داده‌های آموزشی بهترین مقادیر را برای این متغیرها یافت. به‌طور کلی در الگوریتم‌هایی که داده‌ها به‌صورت ضرب نقطه‌ای ظاهر می‌شوند، می‌توان از ایده هسته استفاده کرد. متناسب با کاربرد مسئله، انواع مختلفی از توابع هسته ایجاد شده‌اند، که از مهم‌ترین این هسته‌ها که عمومیت بیشتری نیز دارند، می‌توان به هسته‌های چند جمله‌ای، گوسی، خطی، فازی و موارد دیگر اشاره کرد. ایده استفاده از روش چند هسته‌ای در شکل (۷) نشان داده شده است.



(شکل-۷): ایده استفاده از هسته
(Figure-7): The idea of using a kernel

۳-۴-۱- ایجاد مجمع ماشین‌های بردار پشتیبان چند هسته‌ای بهینه

استفاده از نتایج چندین طبقه‌بند با عنوان یادگیری دسته‌جمعی، یک رویکرد مؤثر در یادگیری ماشینی است که در آن به‌منظور بهبود دقت یادگیری، نتایج طبقه‌بندها با یکدیگر ترکیب شده و یک سامانه مرکب شکل می‌گیرد. ترکیب طبقه‌بندها شامل دو بخش است: بخش نخست شامل ایجاد طبقه‌بندهای پایه مناسب، انتخاب نوع طبقه‌بندها، تعداد طبقه‌بندها و ویژگی‌های مناسب برای هر طبقه‌بند است. بخش دوم شامل نحوه ترکیب خروجی طبقه‌بندها به‌منظور حصول بهترین نتیجه برای طبقه‌بندی الگوهاست. در ایجاد طبقه‌بندهای پایه باید

MATHWORK استفاده شد که از ویژگی‌های Cross-covariance دو و سبه‌بعدی، آمارگان گوسین و bicoherence استفاده شد.

۳-۴- ماشین بردار پشتیبان چند هسته‌ای

برای بررسی ماشین بردار پشتیبان چند هسته‌ای، فرض می‌کنیم n داده آموزشی و m بُعد داریم. $x_i^{(m)}$ نشان‌دهنده بردار ویژگی m -آمین بُعد از i -آمین داده آموزشی است و برچسب معادل آن y_i یکی از دو مقدار -1 و 1 است. ماشین بردار پشتیبان چند هسته‌ای تابع هدف را در رابطه زیر بهینه می‌کند [23]:

$$\min_{w^{(m)}, b, \xi} \frac{1}{2} \sum_{m=1}^M \beta_m \|w^{(m)}\|^2 + c \sum_{ij} \xi^i \quad (5)$$

$$s.t.: y_i \left(\sum_{m=1}^M \beta_m (w^{(m)})^T \varphi(x_i^{(m)} + b) \right) \geq 1 - \xi^i$$

$$\xi^i \geq 0, i = 1, \dots, n$$

در رابطه (۵)، $w^{(m)}$ ، $\varphi^{(m)}$ و $\beta_m \geq 0$ به‌ترتیب نشان‌دهنده بردار وزن، تابع هسته نگاشت و وزن هر بُعد برای ترکیب ویژگی‌ها است. فرم دوگان ماشین بردار پشتیبان همانند فرم اولیه آن به‌دنبال بهینه‌کردن تابع معیار در رابطه (۶) آورده شده است [16]:

$$\max_{\alpha} \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{ij} \alpha_i \alpha_j y_i y_j \sum_{m=1}^M \beta_m k^{(m)}(x_i^{(m)}, x_j^{(m)}) \quad (6)$$

$$s.t.: \sum_{i=1}^n \alpha_i y_i = 0$$

$$0 \leq \alpha_i \leq C, i = 1, \dots, n \quad (7)$$

$$f(x^{(1)}, x^{(2)}, \dots, x^{(M)})$$

$$= \text{sign} \sum_{i=1}^n a_i y_i \sum_{m=1}^M m, \beta_m k^{(m)} = (x_i^{(m)}, x_j^{(m)}) + b$$

در رابطه (۶)، تابع هسته برای دو داده آموزشی x_i و x_j روی m -آمین بُعد در آن داده‌ها است. برای داده آزمایش جدید $X = \{X^{(1)}, X^{(2)}, \dots, X^{(M)}\}$ ابتدا مقدار $k^{(m)}(x_i^{(m)}, x_j^{(m)}) = \varphi^{(m)}(x_i^{(m)})^T \varphi^{(m)}(x_j^{(m)})$ که نشان‌دهنده مقدار تابع هسته مورد استفاده میان داده آزمایشی و تمام داده‌های آموزشی روی m -آمین بُعد است، محاسبه می‌شود. رابطه (۷) برای پیش‌بینی برچسب داده آزمایشی اعمال می‌شود [23]. اگر $k(x_i, x_j) = \sum m, \beta_m k^{(m)} = (x_i^{(m)}, x_j^{(m)})$ را به‌عنوان

توجه داشت که به نوعی گوناگون در خطا باشند تا ترکیب نتایج آن‌ها باعث بهبود نرخ بازشناسی سامانه مرکب شود. برای این که بتوان نتیجه مناسبی از ترکیب طبقه‌بندها گرفت، این طبقه‌بندها باید شرایط زیر را داشته باشند: هر یک به تنهایی در حد قابل قبولی دقیق باشند. البته نیازی به بسیار دقیق بودن آن‌ها نیست. هر کدام مکمل دیگری عمل کنند. به این معنا که همگی نباید مشابه هم بوده و نتیجه یکسانی تولید کنند.

در این روش، از مجموعی از ماشین‌های بردار پشتیبان با هسته‌های مختلف استفاده شده است. از آنجایی که ماشین بردار پشتیبان کارایی مناسب خود را در سامانه‌های مختلف یادگیر ماشین نشان داده است، بنابراین از این طبقه‌بند به عنوان طبقه‌بند پایه استفاده شده، اما سؤال این جا است که چرا مجموعی از ماشین‌های بردار پشتیبان برای طبقه‌بندی نهایی استفاده شده است. در پاسخ به این سؤال باید گفت نخست این که همان گونه که در بخش‌های قبلی نیز یاد شد، مدل‌های جمعی کارایی مناسب‌تری را نسبت به مدل‌های تکی از خود نشان داده‌اند و دوم این که برای افزایش کارایی و درواقع ایجاد تنوع در طبقه‌بند پایه از مدل جمعی ماشین بردار پشتیبان چند هسته‌ای استفاده شده است. هسته‌های مختلف برای ماشین‌های بردار پشتیبان می‌تواند باعث ایجاد تنوع در نتایج حاصله از هر طبقه‌بند شده و در نتیجه رأی‌گیری حاصله با دقت بالایی صورت گیرد. در روش پیشنهادی برای ترکیب خروجی طبقه‌بندها از روش رأی اکثریت استفاده شده است. در رأی اکثریت، اظهار نظر هر طبقه‌بند در مورد طبقه الگوی ورودی، به عنوان یک رأی محسوب می‌شود و تصمیم‌گیری نهایی بر اساس رأی دریافت‌شده از طبقه‌بندهای مختلف صورت می‌گیرد. الگوی ورودی به طبقه‌ای تعلق خواهد گرفت که بیشترین رأی را بیاورد. فرض کنیم خروجی‌های طبقه‌بندها به صورت بردارهای دودویی C -بعدی $[d_{i,1}, d_{i,2}, \dots, d_{i,n}]$ بوده به طوری که $d_{i,1}$ اگر طبقه‌بند D_i نمونه X را در دسته ω_j قرار داده باشد و در غیر این صورت $d_{i,j} = 0$ است. رأی حالت تعدد برای دسته ω_k از فرمول (۸) محاسبه می‌شود.

$$\sum_{i=1}^L d_{i,k} = \max_{j=1}^c \sum_{i=1}^L d_{i,j} \quad (8)$$

اگر در حالت برای مثال دوطبقه‌ای ($c = 2$) بیشینه ساده (۵۰ درصد رأی‌ها به علاوه یک) به یک طبقه k رأی بدهند، این رأی، رأی بیشینه نامیده می‌شود.


داخل فضای ویژگی‌ها با استفاده از موجک و AR و ویژگی‌های زمانی نگاشت می‌شوند. در مرحله یادگیری SVM-ها چند نمونه را به عنوان ورودی دریافت می‌کنند. این الگوها ضربان‌های قلب هستند که به وسیله m پارامتر ویژگی که می‌تواند به عنوان نقاط در فضای m -بعدی دیده شوند، نشان داده می‌شوند؛ سپس ماشین قادر می‌شود که برچسب بردارهای جدید را با مقایسه آن‌ها با نمونه‌هایی که در مرحله یادگیری استفاده شده بود، پیدا کند.

۱-۴-۳- تنظیم پارامترهای SVM به وسیله الگوریتم ژنتیک

انتخاب زیرمجموعه بهینه به عنوان ورودی طبقه‌بند یک گام مهم دیگر در بهینه‌سازی ماشین‌های بردار پشتیبان به منظور طبقه‌بندی سیگنال‌های ECG است. هرچند ماشین‌های بردار پشتیبان در فضای با ابعاد بالا پایدار هستند، ولی انتخاب زیرمجموعه بهینه از پارامترها می‌تواند عملکرد طبقه‌بند را از لحاظ دقت، سرعت و هزینه بهبود ببخشد [23].

با توجه به عوامل تأثیرگذار بر عملکرد ماشین‌های بردار پشتیبان، به منظور تعیین یک سامانه طبقه‌بند بهینه در فضای با ابعاد بالا، می‌بایست از یک روش بهینه‌سازی قدرتمند بهره برد [23]. با توجه به انعطاف‌پذیری و سرعت هم‌گرایی مناسب و سادگی الگوریتم ژنتیک نسبت به دیگر روش‌های یادگیر تقلید از طبیعت، در این پژوهش از این الگوریتم به منظور انتخاب بهینه پارامترهای ماشین بردار پشتیبان استفاده شده است.

هر کروموزوم نمایش‌گر دو پارامتر تنظیم و کرنل در SVM است که با یک رشته از صفر و یک تعریف می‌شود (شکل ۸). طول بردار از کروموزوم‌ها متناسب با محدوده تغییرات پارامترها و همچنین دقت مورد نیاز مسأله تعیین می‌شود.



(شکل ۸): نمایش دودویی پارامترهای ماشین‌های بردار پشتیبان
(Figure-8): Binary parameters for the support vector machines

برای ارزیابی کیفیت هر عضو، می‌بایست هر یک از دو قسمت بردار به عدد حقیقی تبدیل شود. برای این منظور، از رابطه (۹) استفاده می‌کنیم.

و این مراحل تکرار می‌شود تا شرط توقف برقرار شود (شکل ۹).

۳-۵- انتخاب داده‌های آموزش و آزمون

در آخرین مرحله از پیش‌پردازش سیگنال، ۱۰۶۰ ضربان از هر یک از طبقه‌های شش‌گانه به‌صورت به‌طور کامل تصادفی انتخاب می‌شوند که تعداد ۷۵۰ ضربان به‌عنوان داده آموزش و ۳۱۰ ضربان به‌عنوان داده آزمون در نظر گرفته شده و در طبقه‌بندی مجزا ذخیره می‌شود. تعداد ۷۵۰ ضربانی که به‌عنوان داده‌های آموزشی در نظر گرفته شده‌اند، به دو بخش پانصدتایی به‌عنوان آموزشی و ۲۵۰ تایی به‌عنوان اعتبارسنجی تقسیم می‌شوند. هر جایی که به داده‌های اعتبارسنجی احتیاج نباشد، کل داده‌های آموزشی و اعتبارسنجی به‌عنوان داده‌های آموزشی در نظر گرفته می‌شوند.

۴- آزمایش‌ها و ارزیابی نتایج تجربی


در این بخش نتایج تجربی و آزمایش‌های مختلف برای روش پیشنهادی تشریح شده است. روش پیشنهادی در محیط نرم‌افزار متلب، با سیستم عامل ویندوز ۷ و با پردازنده اینتل هفت هسته‌ای، پیاده‌سازی شده است. در آزمایش‌ها، از سه پایگاه داده ECG مختلف برای ارزیابی روش پیشنهادی استفاده شده که در ادامه هر کدام تشریح شده است.

مجموعه داده نخست: پایگاه داده استاندارد-MIT-BIH

سیگنال‌های ECG مربوط به بیماران مختلف از پایگاه داده استاندارد MIT-BIH تهیه شده‌اند. این پایگاه داده دارای ۴۸ سیگنال ECG دوکاناله است که از ۴۷ مورد مطالعاتی در آزمایشگاه آریتمی BIH بین سال‌های ۱۹۷۵ تا ۱۹۷۹ به‌دست آمده است. سیگنال‌ها با فرکانس ۳۶۰ نمونه بر ثانیه و با دقت دوازده بیت در محدوده ده میلی‌ولت ذخیره شده‌اند. داده‌ها با باند پهن در ۰.۱ تا ۱۰۰ هرتز فیلتر می‌شوند و وضوح آن دویست نمونه در هر ولت است. ۲۳ مورد از ضبط‌شده به‌عنوان نمونه‌ای از ضبط‌های بالینی معمول و ۲۵ مورد ضبط‌شده شامل آریتمی‌های بطنی، اتصالی و بالا بطنی است. بیش از ۱۰۹۰۰۰ ضربان بطنی دارای برجسب از پانزده نوع ضربان قلب مختلف وجود دارد. در تعداد نمونه‌ها در هر نوع ضربان قلب تفاوت زیادی وجود دارد. بزرگترین رده

$$p = \min_p + \frac{\max_p - \min_p}{2^l - 1} \times d \quad (9)$$

که در این رابطه، p مقدار حقیقی پارامتر، $\min_p$ و $\max_p$ به‌ترتیب کمینه و بیشینه مقدار پارامتر، l تعداد بیت‌های نمایش‌گر پارامتر و d مقدار عددی رشته دودویی در پایه ده است. در مرحله بعد هر ماشین‌های بردار پشتیبان به‌وسیله داده‌های آموزشی و پارامترهای محاسبه‌شده، آموزش دیده و ابرصفحه‌های مورد نظر ساخته، سپس به‌منظور محاسبه تابع هدف، داده‌های آزمایش به‌وسیله ماشین‌های بردار پشتیبان آموزش دیده، رده‌بندی و سپس ماتریس خطا تشکیل می‌شود. از ضریب کاپا به‌علت استفاده از تمام اطلاعات ماتریس خطا، به‌عنوان دقت رده‌بندی و تابع هدف در این بخش استفاده شد که با رابطه (۱۰) تعریف می‌شود.



(شکل ۹): نمودار فرآیند تعیین مقادیر بهینه پارامترهای

ماشین‌های بردار پشتیبان بر مبنای الگوریتم ژنتیک

(Figure-9): Process diagram for determining the optimal values of support vector machines based on genetic algorithm

$$Kappa = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} \times x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} \times x_{+i})} \quad (10)$$

در این رابطه، N تعداد کل نمونه‌ها، r تعداد طبقه‌ها، x_{ii} عناصر روی قطر اصلی ماتریس خطا، x_{i+} جمع حاشیه‌ای سطرها و x_{+i} جمع حاشیه‌ای ستون‌ها است. پس از ارزیابی اعضا، دو مرحله شامل، تقطیع و جهش، بر روی فرمت دودویی پارامترها انجام و بردار جدید ساخته

"ضربان طبیعی" با حدود ۷۵۰۰۰ نمونه و کوچکترین رده "ضربان زودرس فوق بطنی" (SP) فقط با دو مثال است. پایگاه داده هم در اطلاعات زمان بندی و هم در طبقه بندی، ضریب نمایه می شود. برای اطلاعات بیشتر در مورد پایگاه داده آریتمی MIT – BIH به [44] مراجعه کنید. ما از هشت رکورد (۱۱۸، ۱۲۴، ۲۰۷، ۲۰۸، ۲۰۹، ۲۱۴، ۲۲۲ و ۲۲۳) از پایگاه داده استفاده کردیم. از فایل های فهرست پایگاه داده برای یافتن ضربات در سیگنال های ECG استفاده کردیم.

مجموعه داده دوم:

St-Petersburg Institute of Cardiological Technics 12-lead arrhythmia database (INCART) [44]

این پایگاه داده شامل ۷۵ رکورد است که حاوی یادداشت و استخراج از ۳۲ پرونده هولتر است. هر فایل از چندین بیمار (۱۷ مرد و ۱۵ زن، بین ۱۸ تا ۸۰ سال) که تحت آزمایش های بیماری عروق کرونر قرار گرفته بودند، جمع آوری شده است. مدت زمان هر رکورد سی دقیقه و نمونه برداری در ۲۵۷ هرتز است. حاشیه نویسی ها توسط یک الگوریتم خودکار تولید شده و سپس به صورت دستی اصلاح می شوند.

مجموعه داده سوم:

MITBIH supraventricular arrhythmia database (SVDB) [44] :

این بانک اطلاعاتی شامل ۷۸ رکورد با نمونه برداری ۱۲۸ هرتز است. نوع نوشتن ضربان ثبت ها ابتدا به طور خودکار توسط اسکنر Marquette Electronics 8000 Holter انجام شد و بعدها توسط دانشجوی پزشکی دیگری مورد بررسی و تصحیح قرار

برای ارزیابی عملکرد، ما نتایج را از نظر VEB (کلاس V در مقابل N، S و F) و SVEB (کلاس S در مقابل V، N و F) ارائه می دهیم. به طور خاص، از معیارهای استاندارد استفاده خواهد شد: حساسیت (Se)، مقدار پیش بینی مثبت درست (PP)، فراخوان (Sp)، دقت کلی (ACC).

(جدول ۴): ماتریس ابهام

(Table-4): Confusion matrix

		کلاس درست	
		مثبت	منفی
حدا فرضیه	مثبت	مثبت درست (TP)	مثبت اشتباه (FP)
	منفی	منفی اشتباه (FN)	منفی درست (TN)

جدول (۴) ماتریس ابهام را نشان می دهد. معیار عملکرد تعریف شده روی مجموعه داده هایی با دو رده یا مجموعه داده های نامتعادل بر اساس ماتریس ابهام یاد شده

استوار می شوند. برای مثال، مجموعه داده ای را در نظر بگیرید که یک رده اقلیت حاوی پنج درصد از کل نمونه ها و یک رده بیشینه حاوی بقیه ۹۵ درصد از کل نمونه ها باشد. طبقه بندی که همواره برای رده بیشینه رأی می دهد (صرف نظر از اینکه چه نمونه ای باشد) دارای دقت ۹۵ درصدی است (با وجود عملکرد بسیار پایینش در تشخیص کلاس اقلیت). بررسی ماتریس ابهام این نکته را بر ما روشن می سازد که ستون نخست تعداد نمونه های مثبت و دومین ستون تعداد نمونه های منفی را نشان می دهد، همچنین روشن است که نخستین سطر ماتریس ابهام تعداد نمونه هایی را نشان می دهد که طبقه بندی آموزش یافته آن ها را به عنوان نخستین رده (رده اقلیت) تشخیص می دهد و سطر دوم از ماتریس ابهام تعداد نمونه هایی را نشان می دهد که طبقه بندی آن ها را به عنوان رده دوم (رده بیشینه) شناسایی می کند. ستون های ماتریس ابهام توزیع نمونه های رده را نشان می دهد. درحقیقت هر معیاری که از آن ها به طور هم زمان استفاده می کند، نمی تواند عاری از حساسیت نسبت به نبود تعادل رده باشد. برای مثال، معیار دقت از هر دو ستون استفاده می کند و بنابراین نسبت به نبود تعادل حساس است؛ یعنی با تغییر دادن توزیع های رده مجموعه داده، این معیار ممکن است، تغییر کند؛ درحالی که عملکرد تغییر نکرده است. بعضی معیارهایی که برای ارزیابی عملکرد یادگیری در مجموعه داده های دارای دو رده یا مجموعه داده های نامتعادل تنظیم می شوند، عبارتند از: دقت، صراحت، فراخوانی.

دقت با استفاده از معادلات (۹ تا ۱۱) به دست می آید.

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (9)$$

صحت با معادله (۱۰) به دست می آید.

$$PP = \frac{TP}{TP + FP} \quad (10)$$


فراخوانی با معادله (۱۱) به دست می آید.

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

نمودارهای ترسیم شده در شکل (۱۰)، نمونه ای از ویژگی های آموزش داده شده را برای هر طبقه نشان می دهد. این شکل میانگین ضربان را از بانک اطلاعاتی MIT-BIH که به وسیله چهار رده N، SVEB، VEB و F طبقه بندی شده است، نشان می دهد. نمودارهای ترسیم شده در شکل (۱۰) به صورت زیر تشریح شده اند:

تابع پایه db6، نمودار شکل (c) بازه HOS برای چولگی و کشیدگی و نمودار شکل (d) هیستوگرام HOS و DWT.

(a) پنجره متمرکز شده در قله R از سیگنال خام ECG،
(b) استخراج ویژگی‌های خطی از تبدیل ویولت گسسته با



(شکل-۱۰): میانگین ضربان از بانک اطلاعاتی MIT-BIH که توسط چهار رده N، SVEB، VEB و F طبقه‌بندی شده است.

(a) پنجره متمرکز شده در قله R از سیگنال خام ECG، (b) استخراج ویژگی‌های خطی از تبدیل ویولت گسسته با تابع پایه db6 (c) بازه

HOS: چولگی و کشیدگی (d) هیستوگرام HOS و DWT

(Figure-10): Average beats from the MIT-BIH database grouped by the four AAMI class (N, SVEB, VEB, and F) (a) 180 window centered on R-

(جدول-۵): مقایسه روش‌های مختلف با روش پیشنهادی روی مجموعه داده MIT-BIH

(Table-5): Comparison of different methods with the proposed method on the MIT-BIH dataset

Method	Feature set	Classifier	Effectiveness
de Chazal et al. [45]	ECG-Intervals, Morphological	Weighted LD	Acc = 83%; PP = 87%; SP = 76%; +P = 82%;
Soria and Martinez [46]	RR-Intervals, VCG, morphological + FFS	Weighted LD	Acc = 90%; PP = 92%; SP = 88%; +P = 93%;
Llamedo and Martinez [47]	Wavelet; + SFFS	Weighted LD	Acc = 93%; PP = 95%; SP = 77%; +P = 87%;
Mar et al. [48]	Temporal Features; + SFFS	Weighted LD	Acc = 89%; PP = 89%; SP = 83%; +P = 75%;
Lin, C.-C. & Yang [49]	Morphological, Wavelet	SVM, IWKLR, DTSVM	Acc = 97% (DS1); Acc = 92% (DS2)
Huang, et al. [50]	features proposed in, [51]	SVM, ANN, Bayesian, OPF	Acc = 84%; PP = 87%; SP = 80%; +P = 77%;
Ye et al. [51]	Morphological, Wavelet, PCA ICA, RR interval	SVM	Acc = 86.4%; PP = 88%; SP = 97%; +P = 63%;
de Lannoy et al. [52]	ECG-Intervals, HOS, morphological, HBF, coefficients	weighted SVM	Acc = 83%; PP = 80%; SP = 88%; +P = 79%;
Park et al. [53]	HOS, HBF	Hierarchical SVM	Acc = 85%; PP = 86%; SP = 82%; +P = 80%;
Zhang and Luo [54]	RR-intervals, morphological features, ECG-intervals and segments	Combined SVM	Acc = 86%; PP = 89%; SP = 79%; +P = 92%;
Proposed method	DWT+HOS	Combined Optimal Multi-kernel SVM	Acc = 98%; PP = 97%; SP = 97%, +P = 96%;

ANN, Artificial Neural Network; PCA, Principal Component Analysis; FFS, Floating Feature Selection; ICA, Independent Component Analysis; BPNN, Back Propagation Neural Network; HBF, Hermite Basis Function; HOSC, high order statistics cumulants; LD, Linear Discriminants; SFFS, Sequential forward floating search; IWKLR, Importance Weighted Kernel Logistic Regression; CRF, Conditional Random Fields; RC, Reservoir Computing; \$ Authors optimize their result for 3 classes (N, SVEB, VEB); # Where confusion matrix was not given, some values could not be computed.

از نظر معیارهای مختلفی از جمله دقت، صحت، فراخوانی و نرخ مثبت درست با سایر روش‌های رقیب مقایسه کرده

روش‌های مختلف به‌همراه ویژگی‌هایشان در جدول ۵ آورده شده است. جدول (۵) روش پیشنهادی را

زمان اجرا با سایر روش‌های رقیب مقایسه کرده است. نتایج جدول (۷) نشان می‌دهد زمان اجرای روش پیشنهادی نسبت به سایر روش‌های رقیب افزایش چشم‌گیری ندارد. جدول (۸) روش پیشنهادی را با روش‌های مختلف که از فنون انتخاب ویژگی متفاوتی استفاده کرده‌اند، از نظر دقت مورد مقایسه قرار داده است. اشکال ۱۱ و ۱۲ روش پیشنهادی را با سایر روش‌های SVM مقایسه کرده و نشان داده شده که روش پیشنهادی برتری چشم‌گیری نسبت به سایر روش‌ها دارد.

است. نتایج جدول (۵) حاکی از برتری روش پیشنهادی است. جدول (۶)، دقت طبقه‌بندی سیگنال ECG با استفاده از ۵ روش طبقه‌بندی را نشان می‌دهد. این طبقه‌بندی با انتخاب چهل ویژگی و ۷۵۰ داده آموزش انجام شده است. با توجه به نتایج حاصل‌شده از جدول (۶) روش ترکیبی پیشنهادی عملکرد بهتری نسبت به سایر روش‌ها از خود نشان داده است (جدول (۶) ترکیب روش‌های انتخاب ویژگی مختلف با ماشین بردار پشتیبان چندهسته‌ای است). جدول (۷) روش پیشنهادی را از نظر

(جدول-۶): دقت طبقه‌بندی با استفاده از ۵ روش طبقه‌بندی با انتخاب ۴۰ ویژگی روی مجموعه داده MIT-BIH
(Table-6): Accuracy of classification using 5 classification methods by selecting 40 attributes on the MIT-BIH dataset

روش	A	L	N	P	R	V	دقت
SVMs-PCA	95.98	96.44	93.58	92.56	90.46	91.35	93.42
SVMs-NMI	96.12	96.75	95.90	94.12	96.27	97.62	96.13
SVMs- GA	96.24	97.56	98.91	99.56	99.82	99.53	98.60
SVMs-NMI-GA	98.86	99.12	99.54	99.80	100	99.90	99.53
Proposed	100	100	99.91	100	100	100	99.98

(جدول-۷): مقایسه روش‌های مختلف از نظر زمان اجرا
(Table-7): Comparison of different methods in terms of run time


الگوریتم‌ها	مجموعه داده‌ها		
	MIT-BIH	INCART	SVDB
de Chazal et al.] 45[	2.635	3.660	3.660
Soria and Martinez] 46[	4.449	5.468	5.468
Llamedo and Martinez] 46[	4.020	4.635	4.635
Mar et al.] 48[	4.447	4.904	4.904
Lin, C.-C. & Yang] 49[	5.707	6.368	6.368
Huang, et al.] 50[	2.332	5.856	5.856
Ye et al.] 51[	4.425	4.990	4.990
de Lannoy et al.] 52[	3.038	3.076	3.076
Park et al.] 53[	4.450	4.137	4.137
Zhang and Luo] 54[	3.123	3.442	3.442
Proposed method	4.106	4.441	4.441

(جدول-۸): مقایسه دقت روش پیشنهادی با روش‌های با انتخاب ویژگی مختلف روی مجموعه داده MIT-BIH
(Table-8): Comparison of the accuracy of the proposed method with different feature selection methods on the MIT-BIH dataset

روش	روش انتخاب ویژگی	دقت
Proposed	DWT+HOS	99.98
SVM(nu -S VC)]55[	DWT	94
SVM (DT)]55[	DCT	96.5
SVM (epsilon -SVR)]55[	Amplitude value	94.2
SVM (nu - SVC)]55[	Genetic Algorithm	93.46
SVM (nu -SVC)]55[	PCA	80.00
RNN]55[	Lyapunov exponents	94.72
DAGSVM]55[	SVD	97.71
SIMCA]55[	PCA	98.33

به‌لحاظ ساختاری از چندین ابرصفحه استفاده می‌کند، باعث می‌شود که قدرت تفکیک‌پذیری برای طبقه‌بند بالا برود.

نمودارهای ترسیم‌شده در شکل (۱۴)، به‌کارگیری SVM را در (الف) حالت معمولی و در (ب) روش پیشنهادی از نظر دقت صحت و نرخ مثبت درست نشان می‌دهد.




(شکل-۱۴): به‌کارگیری SVM را در (الف) حالت معمولی و در (ب) روش پیشنهادی از نظر دقت صحت و نرخ مثبت درست بر

روی مجموعه داده SVDB

(Figure-14): Application of SVM in (a) Normal mode and (b) Proposed method in terms of accuracy and positive rate correct on SVDB dataset

شکل (۱۵) دقت روش پیشنهادی را برای دو حالت استخراج ویژگی با HOS و بدون استخراج ویژگی نشان می‌دهد (در محور عمودی، %OA دقت را نشان می‌دهد). نتایج نمودار حاکی از این است که روش پیشنهادی با به‌کارگیری روش استخراج ویژگی با HOS دقت بالاتری را از خود نشان داده است.




(شکل-۱۵): مقایسه روش پیشنهادی در دو حالت استفاده از

HOS و بدون استفاده از HOS روی مجموعه داده

استاندارد MIT-BIH


(Figure-15): Comparison of the proposed method in two modes of HOS use without HOS on the standard MIT-BIH



(شکل-۱۱): مقایسه روش‌های استفاده‌کننده از SVM

بر روی پایگاه داده استاندارد MIT-BIH


(Figure-11): Comparison of methods using SVM on a database MIT-BIH standard



(شکل-۱۲): مقایسه روش‌های استفاده‌کننده از SVM

بر روی پایگاه داده استاندارد INCART

(Figure-12): Comparison of methods using SVM on a database INCART standard




(شکل-۱۳): مقایسه روش پیشنهادی با هسته‌های مختلف و

بهینه بر روی مجموعه داده استاندارد MIT-BIH

(Figure-13): Comparison of the proposed method with different optimal kernels on the standard MIT-BIH dataset


در شکل (۱۳) همان‌طور که مشاهده می‌شود استفاده از هسته در ساختار SVM باعث بهبود نتایج و افزایش معیار فراخوانی (محور عمودی، Se فراخوانی را نشان می‌دهد) طبقه‌بندی شده است. استفاده از هسته‌های غیرخطی باعث می‌شود تا نداشت داده‌ها به عمق بالاتر بهتر انجام گیرد که نتیجه آن افزایش عملکرد طبقه‌بندی می‌شود. از آنجایی که طبقه‌بند پیشنهادی

شکل (۱۶) دقت روش پیشنهادی را برای دو حالت استخراج ویژگی با DWT و بدون استخراج ویژگی نشان می‌دهد. نتایج نمودار حاکی از این است که روش پیشنهادی با به کارگیری روش استخراج ویژگی با DWT دقت بالاتری را از خود نشان داده است.



(شکل - ۱۶): مقایسه روش پیشنهادی در دو حالت استفاده از DWT و بدون استفاده از DWT روی مجموعه داده استاندارد MIT-BIH
(Figure-16): Comparison of the proposed method in DWT mode with and without DWT on MIT-BIH standard dataset

شکل (۱۷) دقت روش پیشنهادی را برای دو حالت استخراج ویژگی با ترکیب DWT و HOS و همچنین بدون استخراج ویژگی نشان می‌دهد. نتایج نمودار حاکی از این است که روش پیشنهادی با به کارگیری روش استخراج ویژگی پیشنهادی دقت بالاتری را از خود نشان داده است.



(شکل - ۱۷): مقایسه روش پیشنهادی در دو حالت استفاده از DWT و HOS و بدون استفاده از DWT و HOS روی مجموعه داده استاندارد MIT-BIH

(Figure-17): Comparison of the proposed method in two cases using DWT and HOS and without using DWT and HOS on MIT-BIH standard dataset

۵- نتیجه گیری

در این بخش به بررسی نتایج به دست آمده از اجرای روش پیشنهادی و مقایسه آن با روش های پیشین و در نهایت به جمع بندی و ارائه پیشنهاد، پرداخته خواهد شد.

در این پژوهش طبقه بندی آریتمی قلبی و سیگنال نرمال انتخاب شده بر روی سه مجموعه داده بررسی شده است. در این مدل ابتدا سعی در حذف انواع نوفه کرده و همچنین به کمک مدل آمیخته گوسی توانستیم

ضربان های پرت را از سیگنال های ECG حذف کرده و سیگنال عاری از نوفه داشته باشیم. در این مدل همچنین برای افزایش دقت مدل و کاهش تعداد ویژگی های نامناسب از روش ترکیبی سیگنال های خطی و غیرخطی استفاده شده است. برای استخراج ویژگی های خطی از تبدیل ویولت گسسته با تابع پایه db6 استفاده شده و برای استخراج ویژگی های غیرخطی از higher order spectra یا HOS استفاده شده است. در انتخاب بهینه ویژگی، رویکردی مناسب جهت دستیابی به دو هدف است:

- افزایش دقت طبقه بندی
- انتخاب تعداد ویژگی کمتر (ویژگی های برتر)

انتخاب تعداد ویژگی کمتر باعث کاهش محاسبات خواهد شد و این درحالی است که با انتخاب تعداد ویژگی کمتر، دقت بهتری نسبت به حالتی که تمامی ویژگی ها به SVMs اعمال می شود، مشاهده شد. هم چنان که از نتایج حاصل شده در بخش قبل مشاهده شد، روش پیشنهادی که از مجمع ماشین های بردار پشتیبان استفاده کرده به طور کامل نسبت به سایر روش ها برتری دارد؛ بنابراین می توان نتیجه گرفت که از اجماع چندین طبقه بند SVM می توان با دقت قابل قبولی سیگنال ECG را طبقه بندی کرد؛ این در حالی است که بتوان اصل تنوع را برای آرای حاصله از خروجی هر طبقه بند ایجاد کرد. در این روش برای برقراری تنوع آرای حاصله از هر SVM از هسته های مختلف برای SVM ها استفاده شده است. نتایج جدول و نمودارهای بخش نتایج تجربی حاکی از این بوده که روش مجمع SVMs نسبت به روش تکی SVM و سایر روش های رقیب دقت بهتری را در طبقه بندی سیگنال ECG ارائه نموده است. همچنین در این روش برای افزایش دقت طبقه بندی، از انتخاب ویژگی مناسبی استفاده شد که ترکیبی از روش خطی و غیرخطی بوده است. نتایج حاصله بخش قبل حاکی از این بوده که روش انتخاب ویژگی پیشنهادی در افزایش دقت طبقه بندی مؤثر واقع شده است. روش پیشنهادی برای به دست آوردن هسته های بهینه از الگوریتم بهینه سازی ژنتیک استفاده کرده است که این بهینگی هسته ها در افزایش دقت طبقه بندی نهایی مؤثر واقع شد. می توان در نهایت نتیجه گرفت که روش پیشنهادی با دقتی معادل ۹۹/۱۵ توانسته به خوبی سیگنال های ECG را طبقه بندی کند.

در نهایت، با توجه به نتایجی که از تحلیل بر روی مجموعه داده جمع آوری شده به دست آورده شده، نکاتی

support Vector Machins ", The 4th Irananin Electrical and Electronic Engineering Conference. 2011.

- [13] N. Acir, "A support vector machine classifier algorithm based on a perturbation method and its application to ECG beat recognition systems", *Expert Systems with Applications*, 2006, vol. 31, no. 1, pp. 150–158.
- [14] M. Chawla, "A comparative analysis of principal component and independent component techniques forelectrocardiograms", *Neural Comput. Appl.* Vol. 18 (6), pp. 539–556, 2009.
- [15] L. Kanaan, Merheb, D., Kallas, M., Francis, C., Amoud, H., Honeine, P., PCA and KPCA of ECG signals with binary SVMclassification, in: *IEEE Workshop on Signal Processing Systems (SiPS)*, 2011, pp. 344–348.
- [16] R.O. Duda, P.E. Hart, D.G. Stork, Pattern Classification, 2nded., Wiley-Interscience, 2000.
- [17] C.M. Bishop, Pattern Recognition and Machine Learning, 1sted., Springer, 2006.
- [18] S. Theodoridis, K. Koutroumbas, Pattern Recognition, 4thed., Elsevier, 2009.
- [19] Y. Bazi, N. Alajlan, H. AlHichri, S. Malek, Domainadaptation methods for ECG classification, in: *InternationalConference on Computer Medical Applications (ICCMMA)*, 2013, pp. 1–4.
- [20] C. Ye, B.V.K. Kumar, M.T. Coimbra, Combining generalmulti-class and specific two-class classifiers for improvedcustomized ECG heartbeat classification, in: *InternationalConference on Pattern Recognition (ICPR)*, 2012, pp.2428–2431.
- [21] C. Ye, V. Bhagavatula, M.T. Coimbra, "Heartbeat classificationusing morphological and dynamic features of ECG signals," *IEEE Trans. Biomed. Eng.* vol.59 (10), 2012, pp. 2930–2941.
- [22] R.G. Kumar, Y.S. Kumaraswamy, "Investigation andclassification of ECG beat using input output additionalweighted feed forward neural network", in: *InternationalConference on Signal Processing, Image Processing &Pattern Recognition (ICSIPR)*, 2013, pp. 200–205.
- [23] E.D. Übeyli, "Combining recurrent neural networks witheigenvector methods for classification of ECG beats", *Digit.Signal Process.* Vol.19 (2), 2009, pp. 320–329.
- [24] T. Mar, S. Zaunseeder, J.P. Martínez, M. Llamado, R. "Poll,Optimization of ECG classification by means of featureselection",

جهت دستیابی به تشخیص بهتر بیماری قلبی پیشنهاد شده است:

- اضافه کردن ویژگی‌های مستقل بیشتر می‌تواند خطای الگوریتم را کاهش دهد.
- استفاده از ترکیب طبقه‌بندهای تقویت‌شده گوناگون.

6- References

۶- مراجع

- [1] Y.H. Hu , S. Palreddy, W.J. Tompkins; "A Patient-Adaptable ECG Beat Classifier Using a Mixture of Experts Epproach", *IEEE Trans.on Biomed.Eng.* Vol. 44, No. 9, pp. 891 – 900, 1997.
- [2] F. Melgani, And Y. Bazi, "Classification of Electrocardiogram Signals with Support Vector Machines and Particle Swarm Optimization", *IEEE Transactions on Information Technology in Biomedicine*, 2008, VOL. 12, No. 5, pp. 667–677.
- [3] O. Mokhlesi, N. Mehrshad, M. Razavi, "Using composite structures of neural networks in order to diagnose cardiac arrhythmias by integrating wavelet and timing features", *Intelligent systems in electrical engineering*, Vol. 2, No 1. 2011.
- [4] A. C. Guyton, J. Edward. "Textbook of medical physiology", 11th ed.
- [5] A. Khazaei, "Classification of the cardiac arrhythmias". Msc Thesis, Noshirvani University of Technology, 2010.
- [6] D. Kumar, R.K. Tripathy, A. Acharya, "Least square support vector machine based multiclass classification of EEG signals", *WSEAS T Signal Process* 10(1), 2014, pp.86-94.
- [7] C. Lin, Y. Du, T. Chen, Adaptive wavelet network formultiple cardiac arrhythmias recognition, *Expert Syst.Appl.* 34 (4) (2008) 2601–2611.
- [8] Y. Kutlu, D. Kuntalp, Feature extraction for ECG heartbeatsusing higher order statistics of WPD coefficients, *Comput.Method Program Biomed.* 105 (3) (2012) 257–267.
- [9] Z. Dokur, T. Ölmez, ECG beat classification by a novelhybrid neural network, *Comput. Method Program Biomed.* 66 (2-3) (2001) 167–181.
- [10] Matthew, Swain, "A Wavelet Transform Approach to the Analysis of Atrial Fibrillation Electrograms", *College London*, MSci Project, 2011.
- [11] P.S. Addison, Wavelet transforms and the ECG: a review, *Physiol. Meas.* 26 (5) (2005) 155–199.
- [12] A. K. Mimri, K. Shirazi, " Classification of the cardiac arrhythmias based on wavelet and



- [36] A. Khazaei, "Heart Beat Classification Using Particle Swarm Optimization", *I.J. Intelligent Systems and Applications*, Vol.5, No. 6, pp. 25-33, 2013.
- [37] F. Chazal, and R.B. Reilly, "A patient adapting heart beat classifier using ECG morphology and heartbeat interval features", *IEEE Trans. Biomed. Eng.*, vol. 53, no. 12, pp. 2535–2543, 2006.
- [38] M. Vijayavanan, V. Rathikarani, and P. Dhanalakshmi, "Automatic Classification of ECG Signal for Heart Disease Diagnosis using morphological features", *Int. J. of Comput. Sci. and Eng. Technology (IJCSET)*, vol. 5, no. 4, pp. 449-45, 2014.
- [39] A. Ghorbanian, A. Ghaffari, Jalali, C. Nataraj, "Heart arrhythmia detection using continuous wavelet transform and principal component analysis with neural network classifier", *computing in Cardiology IEEE Conference*, pp. 669-672, 2010.
- [40] L.Y. Shyu, Y.H. Wu, W.C. Hu, "Using wavelet transform and fuzzy neural network for VPC detection from the Holter ECG", *IEEE Trans. Biomed. Eng.*, vol. 51, pp.1269–1273, 2004.
- [41] D. Karaboga, B. Basturk, "A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm", *Journal of Global Optimization*, vol.39, pp. 459–471, 2009.
- [42] M. moradi, S. nejatian, H. parvin, K. Bagherifard and V. rezaie, "Clustering and Memory-based Parent-Child Swarm Meta-Heuristic Algorithm for Dynamic Optimization", *JSDP*, vol. 18, no. 3, pp. 127-146, 2021.
- [43] M. Mohammadpour, H. Parvin, M. Sina., "Chaotic genetic algorithm based on explicit memory with a new strategy for updating and retrieval of memory in dynamic environments", *J AI Data Min*, vol. 6, pp.191–205, 2018. (in press)
- [44] M. Mohammadpour, H. Parvin, "Genetic Algorithm Based on Explicit Memory for Solving Dynamic Problems", *In Journal of Advances in Computer Research Sari Branch Islamic Azad University*, vol. 7, no. 2, pp. 53-68, 2016.
- [45] H. Parvin, S. Nejatian, M. Mohammadpour, "Explicit memory based ABC with a clustering strategy for updating and retrieval of memory in dynamic environments", *In Applied Intelligence Springer Nature*, 2018. doi: 10.1007/s10489-018-1197-z.
- [46] G.B. Moody, R.G. Mark, "The impact of the MIT-BIH arrhythmia database," *IEEE Eng. Med. Biol. Mag.*, vol.20 (3), pp.45–50, 2001.
- IEEE Trans. Biomed. Eng.* Vol. 58 (8) 2011, pp. 2168–2177.
- [25] M.A. Escalona-Moran, M.C. Soriano, I. Fischer, C.R. Mirasso, "Electrocardiogram classification using reservoir computing with logistic regression", *IEEE J. Biomed. Health Inform.*, vol.19(3), pp. 892–898, 2015.
- [26] K.S. Park, B.H. Cho, D.H. Lee, S.H. Song, J.S. Lee, Y.J. Chee, I.Y. Kim, S.I. Kim, "Hierarchical support vector machine based heartbeat classification using higher order statistics and hermite basis function", in: *Comput. Cardiol.*, 2008, pp.229–232.
- [27] P. de Chazal, M. O'Dwyer, R.B. Reilly, "Automatic classification of heartbeats using ECG morphology and heartbeat interval features", *IEEE Trans. Biomed. Eng.* Vol.51 (7), pp.1196–1206, 2004.
- [28] G. de Lannoy, D. Francois, J. Delbeke, M. Verleysen, "Weighted SVMs and feature relevance assessment in supervised heart beat classification", in: *Biomedical Engineering Systems and Technologies (BIOSTEC)*, pp.212–223, 2010.
- [29] N. Ozcan, F. Gergen, "Fuzzy support vector machines for ECG arrhythmia detection", in: *IEEE International Conference on Pattern Recognition (ICPR)*, 2010, pp. 2973–2976.
- [30] H. Huang, J. Liu, Q. Zhu, R. Wang, G. Hu, "A new hierarchical method for inter-patient heartbeat classification using random projections and RR intervals", *Biomed. Eng. Online* 13, pp. 1–26, 2014.
- [31] J.A. Nasiri, M. Naghibzadeh, H.S. Yazdi, B. Naghibzadeh, "ECG arrhythmia classification with support vector machines and genetic algorithm", in: *IEEE European Symposium on Computer Modeling and Simulation (EMS)*, pp. 187–192, 2009.
- [32] K. Polat, S. Günes., "Detection of ECG arrhythmia using a differential expert system approach based on principal component analysis and least square support vector machine," *Appl. Math. Comput.*, vol.186 (1), pp. 898–906, 2007.
- [33] M. Moavenian, H. Khorrami, "A qualitative comparison of artificial neural networks and support vector machines in ECG arrhythmias classification," *Expert Syst. Appl.*, vol.37 (4), pp. 3088–3093, 2010.
- [34] N.V. Chawla, K.W. Bowyer, W.P. Kegelmeyer, "Smote: synthetic minority over-sampling technique", *J. Artif. Intell. Res.*, vol. 16 (1), pp. 321–357, 2002.
- [35] S. Ghobadi. "The diagnosis and Classification of the cardiac arrhythmias based on support Vector Machines ", *The 13th Iranian student Electrical and Electronic Engineering Conference*. 2010.



صمد نجاتیان مدرک کارشناسی خود را در سال ۱۳۸۲ در رشته مهندسی برق گرایش الکترونیک از دانشگاه سیستان و بلوچستان و مدرک کارشناسی ارشد خود را در سال ۱۳۸۶ در رشته مهندسی برق گرایش مخابرات از دانشگاه مشهد و در سال ۱۳۹۳ مدرک دکترای خود را در رشته مهندسی برق گرایش مخابرات از دانشگاه صنعتی مالزی دریافت کرد. وی هم‌اکنون دانشیار و عضو هیأت علمی گروه برق دانشگاه آزاد اسلامی واحد یاسوج است. حوزه‌های تخصصی ایشان برق، مخابرات، الگوریتم‌های بهینه‌سازی، طبقه‌بندی و خوشه‌بندی داده‌ها و هوش مصنوعی است. وی تاکنون بیش از ۱۱۰ مقاله علمی در نشریات و کنفرانس‌های معتبر داخلی و خارجی به چاپ رسانیده است. نشانی رایانامه ایشان عبارت است از:

samad.nej.2007@gmail.com



حمید پروین مدرک کارشناسی خود را در سال ۱۳۸۵ در رشته مهندسی کامپیوتر گرایش نرم‌افزار از دانشگاه شهید چمران اهواز و مدرک کارشناسی ارشد و دکترای خود را در سال ۱۳۸۷ و ۱۳۹۲ در رشته مهندسی کامپیوتر گرایش هوش مصنوعی از دانشگاه علم و صنعت ایران دریافت کرد. وی تاکنون بیش از ۱۵۰ مقاله علمی در نشریات و کنفرانس‌های معتبر داخلی و خارجی به چاپ رسانیده است و چندین کتاب چاپ کرده‌اند. نشانی رایانامه ایشان عبارت است از:

parvin@iust.ac.ir



کرم‌الله باقری‌فرد مدرک کارشناسی خود را در سال ۱۳۸۴ در رشته مهندسی کامپیوتر گرایش نرم‌افزار از دانشگاه اصفهان و مدرک کارشناسی ارشد و دکترای خود را به‌ترتیب در سال‌های ۱۳۸۷ و ۱۳۹۵ از دانشگاه نجف آباد و اراک در رشته مهندسی کامپیوتر گرایش نرم‌افزار دریافت کرد. وی از سال ۱۳۸۵ تاکنون عضو هیأت علمی بخش مهندسی کامپیوتر دانشگاه آزاد اسلامی واحد یاسوج است. حوزه‌های تخصصی ایشان داده‌کاوی، یادگیری ماشین و سامانه‌های پیشنهاد دهنده است. وی تاکنون بیش از هشتاد مقاله

- [47] A.L. Goldberger, L.A.N. Amaral, L. Glass, J.M. Hausdorff, P.C.Ivanov, R.G. Mark, J.E. Mietus, G.B. Moody, C.-K. Peng, "H.E.Stanley, Physiobank, physiotoolkit, and physionet:Components of a new research resource for complexphysiologic signals," *Circulation*, vol.101 (23), pp. 215–220, 2015, database and tools available at: <http://www.physionet.org/>.
- [48] Massachusetts Institute of Technology, MIT-BIH ECGdatabase, 2011, Available at: <http://ecg.mit.edu/>.
- [49] M.L. Soria, J.P. Martinez, "Analysis of multidomain featuresfor ECG classification", in: *Comput. Cardiol.*, pp.561–564, 2009.
- [50] M. Llamado, J.P. Martí nez, "Heartbeat classification usingfeature selection driven by database generalization criteria", *IEEE Trans. Biomed. Eng.*, vol. 58 (3), pp. 616–625, 2010.
- [51] E.J.d.S. Luz, T.M. Nunes, V.H.C. De Albuquerque, J.P. Papa, D. Menotti, "ECG arrhythmia classification based onoptimum-path forest," *Expert Syst, Appl*, vol. 40 (9), pp. 3561–3573, 2012.
- [52] Z. Zhang, J. Dong, X. Luo, K.-S. Choi, X. Wu, "Heartbeatclassification using disease-specific feature selection", *Comput. Biol. Med.*, vol. 46, pp. 79–89, 2014.
- [53] I. Saini, D. Singh, and A. Khosla, "Electrocardiogram beat classification using empirical mode decomposition and multiclass directed acyclic graph support vector machine", *Computers and Electrical Engineering*, vol. 40, no. 5, pp. 1774–1787, 2014.
- [54] J. Najlaa, H. Sillas, "A Comparison Between ECG Beat Classifiers Using Multiclass SVM and SIMCA with Time Domain PCA Feature Reduction", *2017 UKSim-AMSS 19th International Conference on Modelling & Simulation*, pp. 126-131, 2017. DOI: 10.1109/UKSim.2017.16.



مریم عظیمی‌فر دانش‌آموخته کارشناسی ارشد رشته نرم‌افزار از دانشگاه علوم تحقیقات تهران (کهگیلویه و بویراحمد) است. وی هم‌اکنون دانشجوی دکترای دانشگاه آزاد اسلامی بوده و در چندین واحد دانشگاهی در رشته رایانه مشغول به تدریس است. نشانی رایانامه ایشان عبارت است از:

Maryam.azimifar@yahoo.com

علمی در نشریات و کنفرانس‌های معتبر داخلی و خارجی
به چاپ رسانیده است.

نشانی رایانامه ایشان عبارت است از:

k.bagheri@iauyasooj.ac.ir

سیده وحیده رضایی دارای مدرک



دکترای ریاضی است. ایشان هم‌اکنون

عضو هیأت علمی دانشگاه آزاد اسلامی

واحد یاسوج است. وی تاکنون بیش از

هفتاد مقاله علمی در نشریات و

کنفرانس‌های معتبر داخلی و خارجی به چاپ رسانیده
است.

نشانی رایانامه ایشان عبارت است از:

vahidehrezaie80@gmail.com