پیش‌بینی آریتمی قلبی در سیگنال ECG با به‌کارگیری مجمعی از ماشین‌های بردار پشتیبان چندهسته‌ای بهینه

مریم عظیمی‌فر[۱]، صمد نجاتیان[۲*]، حمید پروین[۳]، کرم‌الله باقری‌فرد[۴] و وحیده رضایی[۵]

[۱و۴]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 الکترکاردیوگرام (ECG)، بر پایه الگوریتم ژنتیک برای استفاده در یک اجماعی از طبقه‌بندهای ماشین بردار پشتیبان (SVM) چندهسته‌ای که هر کدام از این طبقه‌بندها به‌وسیله یک الگوریتم ژنتیک بهینه شده‌اند، پیشنهاد شده است. پیشتر نشان داده شده که به‌علت خاصیت‌هایش (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 چندهسته‌ای به‌عنوان یک طبقه‌بند ترکیبی بهره می‌گیرد. تنوع اجماع به‌وسیله آموزش هر طبقه‌بند ماشین بردار پشتیبان چندهسته‌ای 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 به‌طور معمول از سیگنال‌ها به‌عنوان ویژگی‌های آن استفاده می‌شود؛ در نتیجه از آن‌جایی که روش‌های طبقه‌بندی سیگنال‌ها با تعداد زیادی ویژگی مواجه هستند و حذف‌نکردن 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 به‌وسیلهٔ الگوریتم ژنتیک با اعمال به یک SVM چندهسته‌ای بررسی می‌شود. از الگوریتم ژنتیک جهت بهینه‌سازی پارامترهای هر کدام از SVM–ها استفاده می‌شود. به‌کمک شبیه‌سازی رایانه‌ای، صحت کلی سامانه برای شناسایی شش نوع ریتم قلبی ٪۹۹/۱۵ به‌دست 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 چندهسته‌ای، اجماع طبقه‌بندی، الگوریتم ژنتیک.

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

Maryam Azimi Far[1], Samad Nejatian[2*], Hamid Parvin[3], Karamollah Bagherifard[4] & Vahideh Rezaie[5]

[1,4]Department of Computer Engineering, Yasooj Branch, Islamic Azad University, Yasooj, Iran

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

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

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

[1] Autoregressive

* Corresponding author

*نویسندهٔ عهده‌دار مکاتبات

• تاریخ ارسال مقاله: ۱۳۹۹/۱/۹ • تاریخ پذیرش: ۱۴۰۰/۹/۲۰ • تاریخ انتشار: ۱۴۰۱/۱۰/۳ • نوع مطالعه: پژوهشی

[Downloaded from jsdp.rcisp.ac.ir on 2026-09-15]

[DOI: 10.52547/jsdp.19.3.65]

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, Esemble 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[1]، درخت‌های تصمیم[2]، یافتن قانون انجمنی[3]، شبکه‌های بیزی، ماشین بردار پشتیبان[4]، خوشه‌بندی[5] و...

هر کدام از این روش‌ها، بستگی به نوع کاربردشان 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[6]، حساسیت[7] و ویژگی[1] 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

[Downloaded from jsdp.rcisp.ac.ir on 2026-09-15]

[DOI: 10.52547/jsdp.19.3.65]

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 نشان‌دهندهٔ یک راه مؤثر برای شناسایی و درمان انواع بیماری‌های قلبی است [2].

برای طراحی یک سامانهٔ 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 توام 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 قبلی نشان داده است که برای استخراج ویژگی از سیگنال‌های ECG خانواده دابیچز 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 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 تزریق 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

[8] specificity

[Downloaded from jsdp.rcisp.ac.ir on 2026-09-15]
[DOI: 10.52547/jsdp.19.3.65]

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 SVMsها توسط الگوریتم ژنتیک برای پیش‌بینی آریتمی‌های قلبی تا به‌حال 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. سیگنالECG در طول هر دوره کاری قلب، دارای منحنی مشخصه‌ای به‌صورت شکل (۱) است.

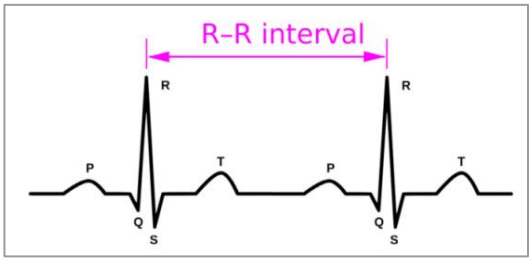

(شکل-۱): یک سیکل از سیگنال ECG [13].
(Figure-1): A cycle of the ECG signal [13].

(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 مراحلی است که طی آن سیگنال ECG به‌عنوان 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 مجموعه‌های‌داده برای انجام اعمال داده‌کاوی انتخاب می‌کند.

الگوریتم‌های انتخاب ویژگی به‌طور کلی به سه دسته تقسیم می‌شوند: مدل‌های فیلتر، مدل‌های رپر[1] (پوششی) و مدل‌های ترکیبی [15]. مدل‌های فیلتر از مشخصات ذاتی یا آماری ویژگی‌های مجموعه‌های‌داده 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 رپرها دارای زمان و هزینه‌های محاسباتی بالاتری بوده و برای مجموعه‌داده‌های با ابعاد بالا مناسب نیست. مزیت اصلی رپرها در دقت بالای پیش‌بینی آن‌ها است. نتایج جستجوی رپرها 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. به‌طور کلی مدل‌های ترکیبی بر اساس رویه‌های ترتیبی دومرحله‌ای کار می‌کنند. در مرحله نخست به‌طورمعمول 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

[Downloaded from jsdp.rcisp.ac.ir on 2026-09-15]
[DOI: 10.52547/jsdp.19.3.65]

(جدول-۲): ویژگی ویولت برای تشخیص مولفه‌های شناختی از ECG [14]

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

ویژگی‌های موجک استخراج شده
انرژی
درصد انرژی طول سیگنال
واریانس ضرایب ویولت
انحراف معیار ضرایب ویولت
مقدار حداکثرتوزیع داده‌ها
انحراف داده‌ها
انحراف استاندارد
میانگین داده‌ها

۲-۲-۱- ویژگی‌های استخراج شده از ویولت

با توجه به این‌که ضرایب موجک (DWT) قادرند اطلاعات زمان-فرکانس سیگنال را به‌طور توام 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 ویولت توصیه شده است [14 - 18].

(جدول-۳): ویژگی زمانی برای تشخیص مؤلفه‌های 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؛ ازاین‌رو، 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 مؤلفه‌های 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 مؤلفه‌های اصلی[1] پرداخته می‌شود. در روش تحلیل مؤلفه‌های 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 وICA 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 به‌وسیلهٔ ICA ویژگی‌های امیدوارکننده‌ای برای طبقه‌بندی ECG هستند؛ علاوه‌بر این، نشان داده شده است که ترکیبی از راه‌کارهای اولیه، یعنی PCA برای کاهش نوفه و

[1] Principal Component Analysis

[Downloaded from jsdp.rcisp.ac.ir on 2026-09-15]

[DOI: 10.52547/jsdp.19.3.65]

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 بینPCA وKPCA انجام شد و نتیجه گرفته شد که KPCA از روش PCA برای طبقه‌بندی سیگنال ECG بهتر عمل می‌کند. به گفته نویسندگان مرجع [22]KPCA به‌دلیل ساختار غیرخطی، عملکرد بهتری دارد. زمانی‌که مجموعه‌ای از ویژگی‌های ضربان قلب به‌عنوان 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] ازSVM استفاده کرد و براساس استاندارد طبقه‌ای AAMI و طرح تقسیم مجموعه داده‌ها که توسط نویسندگان [32] ارائه شده است، اعتبارسنجی کرد. همین نویسندگان ازSVM 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-BIHdatabase باSVM شد، و مقادیر متفاوتی را برای هر طبقه به‌دست آورد. سود حاصل‌شده برای طبقه‌های SVEB و F در پژوهش یادشده گزارش شده است. رویکردهای طبقه‌بندی مختلف دیگری نیز با تغییراتSVM در [34-36] مطرح شده‌اند. از جمله، ترکیبی از تئوری فازی برای پالایش طبقه‌بندیSVM [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 به‌صورت سلسله‌مراتبی با بیشینه سازوکار رأی‌دهی و گزارش بهبود چشم‌گیر، استفاده کرد. نویسندگان مرجع [37] استفاده یک تابع هسته جدید را برایSVM پیشنهاد کردند. در این کار، برای مقایسه نتایج به‌دست‌آمده 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 آن‌جایی‌که SVM یک رفتار منفی برای طبقه‌های نامتوازن ارائه می‌دهد، روش‌های متوازن‌سازی مجموعه‌داده برای مرحله آموزش، که برای این مشکل اندکی مورد بررسی قرار می‌گیرند، می‌توانند در پژوهش‌های آینده مورد مطالعه قرار گیرند. به‌عنوان مثال، روش‌های نمونه‌گیری پیشرفته‌تر، یعنی روش SMOTE [37]. طبقه‌بندی سیگنال ECG با طبقه‌بند ماشین بردار پشتیبان و الگوریتم PSO در 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 به‌عمل 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 طبقه بند SVM می‌شود. در این مقاله از ۲۵۰، ۵۰۰ و۷۵۰ 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 به‌دست‌آمدن 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 مجموعه‌داده بزرگ با آموزش شبکه عصبی، استفاده از موجک 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 به‌کارگیری ویژگی‌های

[Downloaded from jsdp.rcisp.ac.ir on 2026-09-15]

[DOI: 10.52547/jsdp.19.3.65]

مورفولوژیکی، ارائه کرده‌اند. در این روش، از شبکه عصبی احتمالی (PNN) برای مدل‌سازی و به‌دست‌آوردن توزیع بردارهای ویژگی برای طبقه‌بندی استفاده شده است. روش پیشنهادشده 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. به‌دلیل زیادبودن تعداد بردارهای استخراج‌شده به‌وسیلهٔ موجک از آنالیز PCA جهت کاهش ابعاد و به‌عبارتی انتخاب بهترین نمونه‌ها استفاده شده است. شبکه عصبی چندلایه، طبقه‌بندی را بر روی شش طبقه که شامل سیگنال نرمال و پنج اریتمی 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.

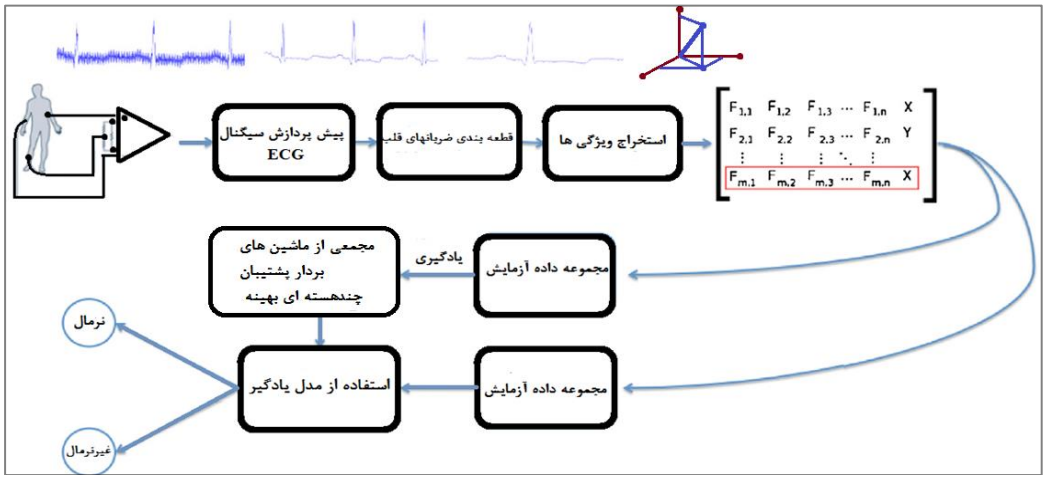

(شکل-۲): ترتیب اجرای الگوریتم‌ها و فنون به‌کار رفته در روش پیشنهادی
(Figure-2): Trend of the algorithms and techniques used in the proposed method

۳- روش پیشنهادی

در این بخش به‌تشریح 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 درنهایت 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 الکتروکاردیوگرافی تغییر کند و درنتیجه، استخراج ویژگی‌های زمانی سیگنال با مشکل مواجه شود.

۳-۱-۲- حذف نوفه ناشی از نفس کشیدن

نوفه ناشی از نفس‌کشیدن 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 درنتیجه، 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 نفس‌کشیدن در آن‌ها حذف شده است.

[Downloaded from jsdp.rcisp.ac.ir on 2026-09-15]
[DOI: 10.52547/jsdp.19.3.65]

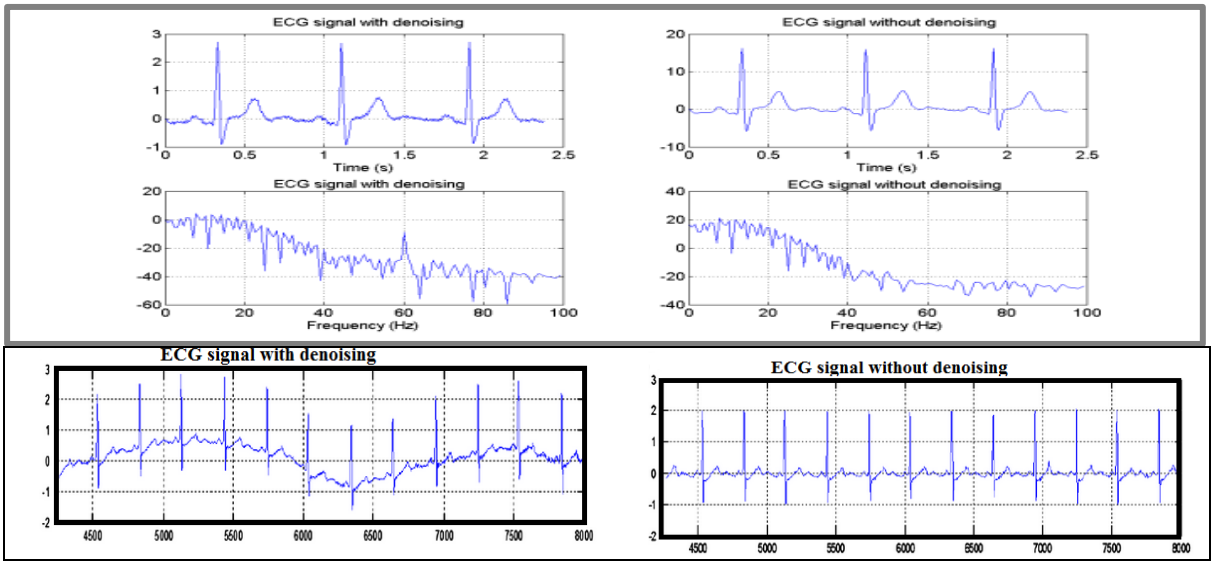

(شکل-۳): حذف نوفه ناشی از نفس‌کشیدن در ۳ سیگنال ECG

(Figure-3): Breathing noise elimination in two ECG signals

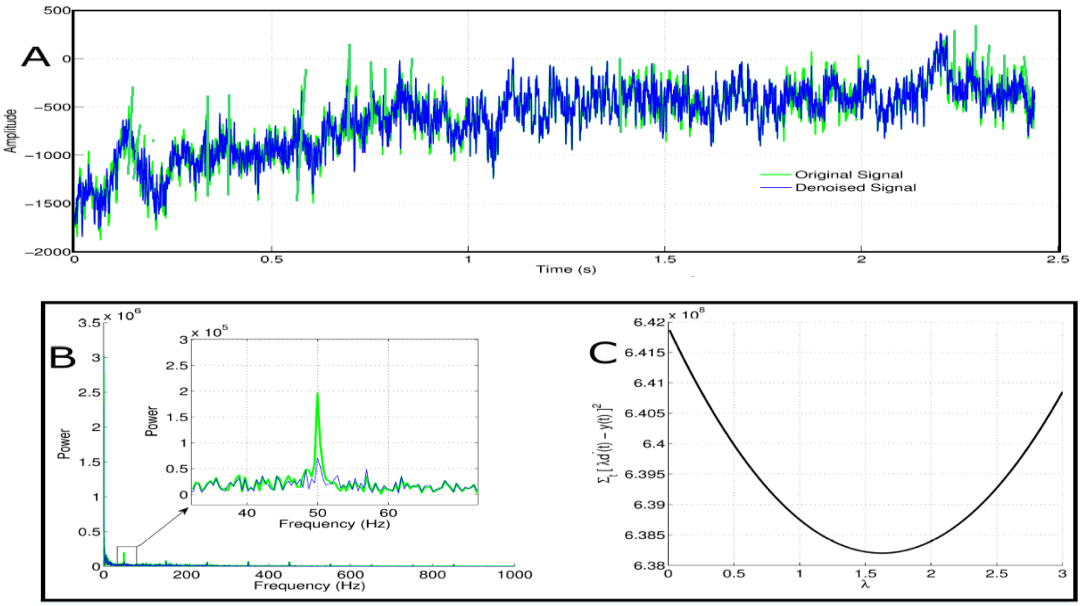

(شکل-۴): یادگیری دامنه نوفه خطوط برق در یک زمینه طبیعی. (A) خط سبزرنگ سیگنال اصلی است و خط آبی‌رنگ سیگنال بازسازی‌شده پس از حذف نوفه شهری. (B) خط سبز نشان‌دهنده طیف قدرت سیگنال اصلی و آبی نشان‌دهندهٔ سیگنال بازسازی شده است. (C) این فرایندی را نشان می‌دهد که دامنه نوفه به‌وسیلهٔ الگوریتم یاد گرفته می‌شود.

(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 فرکانس‌های 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 داده‌های 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

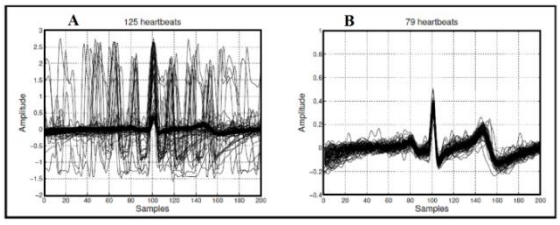

(شکل-۵): A: سیگنال ECG 104 همراه داده‌های پرت

B: سیگنال ECG 104 پس از حذف داده‌های پرت

(Figure-5): A: 104 ECG signal with outbound data
B: 104 ECG signal after deleting outbound data

[Downloaded from jsdp.rcisp.ac.ir on 2026-09-15]
[DOI: 10.52547/jsdp.19.3.65]

نشان می‌دهد که در دو حالت نوفه‌ای و بدون نوفه ارائه شده است. در این شکل خط سبزرنگ سیگنال اصلی است و خط آبی‌رنگ سیگنال بازسازی‌شده 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 به‌صورت 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 به‌طورمعمول برای بازنمایی هر زیرجمعیت از یک توزیع آماری استفاده می‌شود. درواقع هر توزیع ویژگی‌های یک زیر جمعیت را بازنمایی می‌کند، بدون آنکه به توصیف جز به جز جمعیت و تک‌تک مشاهدات بپردازد. مدل آمیخته گاوسی نوع خاصی از مدل‌های آمیخته است که در آن هر زیر جمعیت با یک توزیع گاوسی بازنمایی می‌شود. به‌طور کلی تابع توزیع چگالی احتمال گاوسی یک متغیر تصادفی اسکالر به‌صورت رابطه (۱) است:

$$p(x) = \frac{1}{\sqrt{2\pi\sigma}} e^{-0.5(\frac{x-\mu}{\sigma})^2} = N(\mu,\sigma)^2 \qquad (۱)$$

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

$$p(x) = \frac{1}{\sqrt[D/2]{2\pi}\,|\Sigma|^{1/2}} e^{-0.5(x-\mu)^T \Sigma^{-1}(x-\mu)} \qquad (۲)$$

که در این رابطه x بردار تصادفی، μ بردار میانگین متغیرهای تصادفی و $\sum$ 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 گاوسی مدل شود. الگوریتم بیشینه‌سازی انتظار (EM) برای ساخت GMM استفاده می‌شود. یک روش تکرارشونده (iterative) است که به‌دنبال 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.

۳-۲- قطعه‌بندی سیگنال

در این مقاله، ECG ضبط‌شده در ۲۵۰ هرتز نمونه‌برداری شده و سپس به‌عنوان یک سیگنال دیجیتالی ارائه شده است. برای این مطالعه، هر نمونه ECG به بخش‌هایی به‌طول 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 به‌عنوان سیگنال‌های غیرثابت در نظر گرفته می‌شوند. تجزیه و تحلیل سیگنال ثابت نسبت به سیگنال غیرثابت آسان‌تر است. تقسیم سیگنال به‌عنوان مرحله پیش‌پردازش برای تجزیه و تحلیل سیگنال غیرثابت استفاده می‌شود.

[Downloaded from jsdp.rcisp.ac.ir on 2026-09-15]

[DOI: 10.52547/jsdp.19.3.65]

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

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

$$J(t)=\sum_{k=1}^{d_{t_{k-1}}+1,\ t_k} \qquad (۳)$$

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

$$t'=argmin_{t\in T}(J(t)) \qquad (۴)$$

خطای قطعه $d_{s,t}$ به داده $x_1,x_2,\ldots,x_T$ 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 شکلECG 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.

قطعه‌بندیECG روشی برای یافتن امواج مختلف مانند موج P، کمپلکسQRS ، 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. تجزیه‌وتحلیل ECG شامل تشخیص QRS، امواج P و T و به‌دنبال آن تجزیه‌وتحلیل 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.

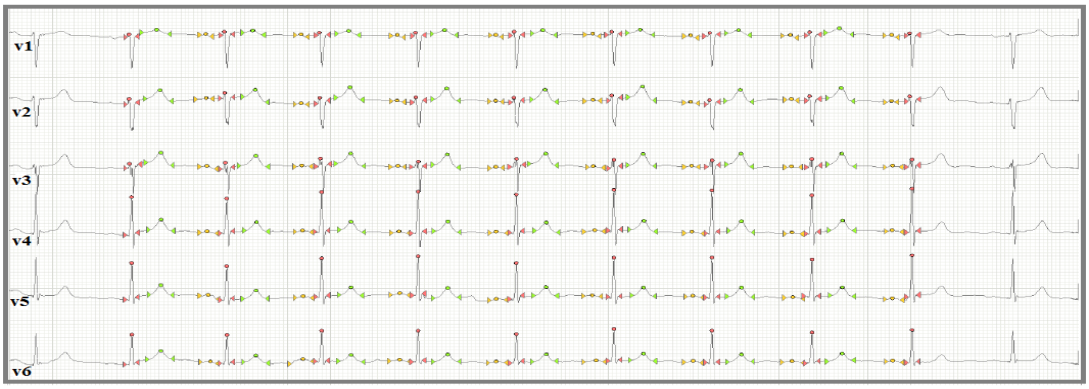

(شکل-۶): نمونه‌ای از قطعه‌بندی سیگنال ECG. رنگ زرد مربوط به امواج P، قرمز به مجتمع های QRS، سبز به امواج T است. علامت ◅ به معنای شروع موج است، ◦ به معنای قله موج است، ▻ مربوط به جابجایی موج است.

(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, ◦ means the wave peak, ▻ corresponds to the offset of a wave.

۳-۳- ویژگی‌های سیگنال

پس از مرحله پیش‌پردازش از سیگنال، ویژگی‌ها استخراج می‌شوند.

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.

۳-۳-۲- ویژگی‌های خطی

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

۳-۳-۳- ویژگی‌های غیرخطی

برای استخراج ویژگی‌های غیرخطی از higher order sperctra یا HOS استفاده شده است. برای این کار از ابزار hosa موجود در تارنمای

[Downloaded from jsdp.rcisp.ac.ir on 2026-09-15]
[DOI: 10.52547/jsdp.19.3.65]

MATHWORK استفاده شد که از ویژگی‌های Cross – covariance دو و سه‌بعدی، آمارگان گوسین و bicoherence استفاده شد.

۴-۳- ماشین بردار پشتیبان چندهسته‌ای

برای بررسی ماشین بردار پشتیبان چندهسته‌ای، فرض می‌کنیم n داده آموزشی و m بُعد داریم. $x_i^{(m)}$ نشان‌دهنده بردار ویژگی m-اُمین بُعد از i-اُمین داده آموزشی است و برچسب معادل آن y_i یکی از دو مقدار -۱ و ۱ است. ماشین بردار پشتیبان چندهسته‌ای تابع هدف را در رابطه زیر بهینه می‌کند [23]:

$$\min_{w^m,b,\xi^i} \frac{1}{2}\sum_{m=1}^{M}\beta_m \|w^{(m)}\|^2 + c\sum_{ij}\xi^i \quad (۵)$$
$$s.t: y_i\left(\sum_{m=1}^{M}\beta_m (w^{(m)})^T \varphi^{(m)}(x_i^{(m)}+b)\right) \geq 1-\xi^i$$
$$\xi^i \geq 0, i=1,\ldots,n$$

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]:

$$\max_{\alpha}\sum_{i=1}^{n}\alpha_i - \frac{1}{2}\sum_{ij}\alpha_i\alpha_j y_i y_i \sum_{m=1}^{M}\beta_m k^{(m)}(x_i^{(m)}, x_j^{(m)}) \quad (۶)$$
$$s.t: \sum_{i=1}^{n}\alpha_i y_i = 0$$
$$0 \leq \alpha_i \leq C, i=1,\ldots,n$$

$$f\left(x^{(1)}, x^{(2)}, \ldots, x^{(M)}\right) = sign\sum_{i=1}^{n} a_i y_i \sum_{m=1}^{M} m,\beta_m k^{(m)} = (x_i^{(m)}, x_j^{(m)}) + b \quad (۷)$$

در رابطه (۶)، تابع هسته برای دو داده آموزشی x_i و x_j روی m-اُمین بُعد در آن داده‌ها است. برای داده آزمایش جدید $X=\{X^{(1)}, X^{(2)}, \ldots, X^{(m)}\}$ ابتدا مقدار $k^{(m)}(x_i^{(m)}, x_j^{(m)}) = \varphi^{(m)}(x_i^{(m)})^T \varphi^{(m)} x^{(m)}$ که نشان‌دهنده مقدار تابع هسته مورد استفاده میان داده آزمایشی و تمام داده‌های آموزشی روی m-اُمین 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 تابع هسته‌ی ادغام‌شده بین دو دادهٔ 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 هسته ادغام‌شده بین دادهٔ آموزشی x_i و داده آزمایشی x در نظر بگیریم، آن‌گاه می‌توان ماشین بردار پشتیبان چندهسته‌ای را به‌وسیله ماشین بردار تک‌هسته‌ای پیاده‌سازی کرد. در روابط بالا این محدودیت وجود دارد که $\sum mB_m = 1$ باشد. می‌توان با قراردادن مقادیر مختلف برای هر B_m و در نظر گرفتن محدودیت یادشده و با استفاده از اعتبارسنجی k-تکه‌ای روی داده‌های آموزشی بهترین مقادیر را برای این متغیرها یافت. به‌طورکلی 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 چندجمله‌ای، گوسی، خطی، فازی و موارد دیگر اشاره کرد. ایده استفاده از روش چندهسته‌ای در شکل (۷) نشان داده شده است.

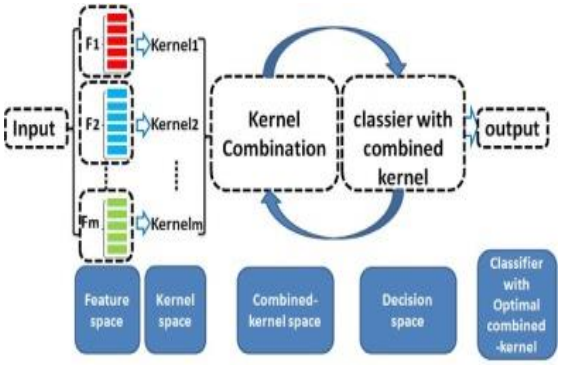

(شکل-۷): ایده استفاده از هسته
(Figure-7): The idea of using a kernel

۳-۴-۱- ایجاد مجمع ماشین‌های بردار پشتیبان چندهسته‌ای 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 طبقه بندها 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

[Downloaded from jsdp.rcisp.ac.ir on 2026-09-15]
[DOI: 10.52547/jsdp.19.3.65]

توجه داشت که به‌نوعی گوناگون در خطا باشند تا ترکیب نتایج آن‌ها باعث بهبود نرخ بازشناسی سامانه مرکب شود. برای این‌که بتوان نتیجه مناسبی از ترکیب طبقه‌بندها گرفت، این طبقه‌بندها باید شرایط زیر را داشته باشند: هر یک به‌تنهایی در حد قابل قبولی دقیق باشند. البته نیازی به بسیار دقیق‌بودن 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 مجمعی از ماشین‌های بردار پشتیبان با هسته‌های مختلف استفاده شده است. از آن‌جایی‌که ماشین بردار پشتیبان کارآیی مناسب خود را در سامانه‌های مختلف یادگیر ماشین نشان داده است، بنابراین از این طبقه‌بند به‌عنوان طبقه‌بند پایه استفاده شده، اما سؤال این‌جا است که چرا مجمعی از ماشین‌های بردار پشتیبان برای طبقه‌بندی نهایی استفاده شده است. در پاسخ به این سؤال باید گفت نخست این‌که همان‌گونه که در بخش‌های قبلی نیز یاد شد، مدل‌های جمعی کارآیی مناسب‌تری را نسبت به مدل‌های تکی از خود نشان داده‌اند و دوم این‌که برای افزایش کارآیی و درواقع ایجاد تنوع در طبقه‌بندهای پایه از مدل جمعی ماشین بردار پشتیبان چندهسته‌ای 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، اظهارنظر هر طبقه‌بند در مورد طبقه الگوی ورودی، به‌عنوان یک رأی محسوب می‌شود و تصمیم گیری نهایی بر اساس آرای دریافت‌شده از طبقه‌بندهای مختلف صورت می‌گیرد. الگوی ورودی به طبقه‌ای تعلق خواهد گرفت که بیشترین رأی را بیاورد. فرض کنیم خروجی‌های طبقه‌بندها به‌صورت بردارهای دودویی c-بعدی $[d_{i,1}, d_{i,2}, \dots, d_{i,n}]$ بوده به‌طوری‌که $d_{i,1}$ اگر طبقه‌بند D_i نمونهٔ X را در دسته ω_j قرار داده باشد و در غیراین‌صورت $d_{i,j} = 0$ است. رأی حالت تعدد برای دسته ω_k از فرمول (۸) محاسبه می‌شود.

$$\sum_{i=1}^{L} d_{i,k} = max_{j=1}^{c} \sum_{i=1}^{L} d_{i,j} \qquad (۸)$$

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

داخل فضای ویژگی‌ها با استفاده از موجک و AR و ویژگی‌های زمانی نگاشت می‌شوند. در مرحلهٔ یادگیری SVM-ها چند نمونه را به‌عنوان ورودی دریافت می‌کنند. این الگوها ضربان‌های قلب هستند که به‌وسیلهٔ m پارامتر ویژگی که می‌تواند به‌عنوان نقاط در فضای m-بُعدی 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.

۱-۱-۴-۳- تنظیم پارامترهای SVM به‌وسیله الگوریتم ژنتیک

انتخاب زیرمجموعه بهینه به‌عنوان ورودی طبقه‌بند یک گام مهم دیگر در بهینه‌سازی ماشین‌های بردار پشتیبان به‌منظور 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، به‌منظور 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 به‌منظور 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.

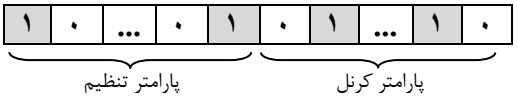

(شکل-۸): نمایش دودویی پارامترهای ماشین‌های بردار پشتیبان

(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.

[Downloaded from jsdp.rcisp.ac.ir on 2026-09-15]

[DOI: 10.52547/jsdp.19.3.65]

$$p = \min_p + \frac{\max_p - \min_p}{2^l - 1} \times d \qquad (۹)$$

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.

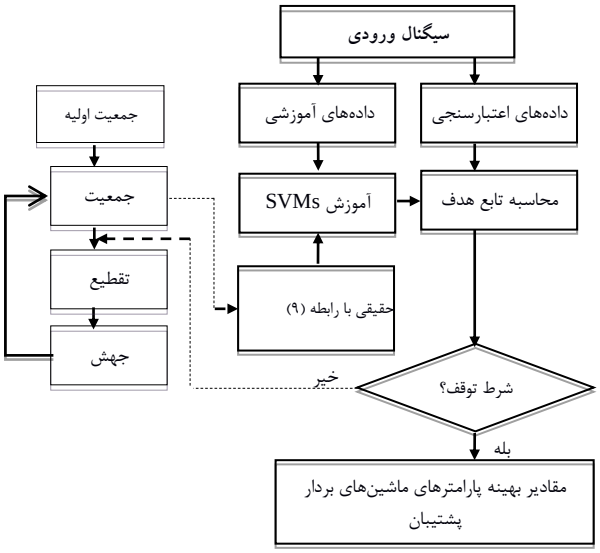

(شکل-۹): نمودار فرآیند تعیین مقادیر بهینه پارامترهای ماشین‌های بردار پشتیبان بر مبنای الگوریتم ژنتیک

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

$$Kappa = \frac{N \sum_{i=1}^{r} x_{ii} - \sum_{i=1}^{r} (x_{i+} \times x_{+i})}{N^2 - \sum_{i=1}^{r} (x_{i+} \times x_{+i})} \qquad (۱۰)$$

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 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 به‌طورکامل 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 ۲۵۰تایی به‌عنوان اعتبارسنجی تقسیم می‌شوند. هر جایی که به داده‌های اعتبارسنجی احتیاج نباشد، کل داده‌های آموزشی و اعتبارسنجی به‌عنوان داده‌های آموزشی در نظر کرفته 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.

مجموعه‌داده 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 میلی ولت 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 برچسب از پانزده نوع ضربان قلب مختلف وجود دارد. در تعداد نمونه‌ها در هر نوع ضربان قلب تفاوت زیادی وجود دارد. بزرگترین ردهٔ

[Downloaded from jsdp.rcisp.ac.ir on 2026-09-15]
[DOI: 10.52547/jsdp.19.3.65]

"ضربان طبیعی" با حدود ۷۵۰۰۰ نمونه و کوچک‌ترین ردهٔ "ضربان زودرس فوق بطنی" (SP) فقط با دو مثال است. پایگاه داده هم در اطلاعات زمان‌بندی و هم در طبقه‌بندی، ضربدر نمایه می‌شود. 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 فایل‌های فهرست پایگاه داده برای یافتن ضربات در سیگنال‌های 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 آزمایش‌های بیماری عروق کرونر قرار گرفته بودند، جمع‌آوری شده است. مدت زمان هر رکورد سی دقیقه و نمونه‌برداری در ۲۵۷ هرتز است. حاشیه‌نویسی‌ها توسط یک الگوریتم خودکار تولیدشده و سپس به‌صورت دستی اصلاح می‌شوند.

مجموعه‌داده سوم:

MITBIH supraventricular arrhythmia database (SVDB) [44] :

این بانک اطلاعاتی شامل ۷۸ رکورد با نمونه‌برداری ۱۲۸ هرتز است. نوع نوشتن ضربان ثبت‌ها ابتدا به‌طور 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 Vدر مقابل N[، S و F] و $SVEB$ (کلاس S در مقابل V[، N وF]) ارائه می‌دهیم. به‌طور خاص، از معیارهای استاندارد استفاده خواهد شد: حساسیت(Se)، مقدار پیش‌بینی مثبت درست (PP)، فراخوان(Sp) ، دقت کلی (ACC).

(جدول-۴): ماتریس ابهام

(Table-4): Confusion matrix

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

جدول (۴) ماتریس ابهام را نشان می‌دهد. معیار عملکرد تعریف‌شده روی مجموعه‌داده‌هایی با دو رده یا مجموعه‌داده‌های نامتعادل بر اساس ماتریس ابهام یادشده استوار می‌شوند. برای مثال، مجموعه‌داده‌ای را درنظر بگیرید که یک رده اقلیت حاوی پنج درصد از کل نمونه‌ها و یک رده بیشینه حاوی بقیه ۹۵ درصد از کل نمونه‌ها باشد. طبقه‌بندی که همواره برای رده بیشینه رأی می‌دهد (صرف‌نظر از اینکه چه نمونه‌ای باشد) دارای دقت ۹۵ درصدی است (با وجود عملکرد بسیار پایینش در تشخیص کلاس اقلیت). بررسی ماتریس ابهام این نکته را بر ما روشن می‌سازد که ستون نخست تعداد نمونه‌های مثبت و دومین ستون تعداد نمونه‌های منفی را نشان می‌دهد، هم‌چنین روشن است که نخستین سطر ماتریس ابهام تعداد نمونه‌هایی را نشان می‌دهد که طبقه‌بند آموزش یافته آن‌ها را به‌عنوان نخستین رده (رده اقلیت) تشخیص می‌دهد و سطر دوم از ماتریس ابهام تعداد نمونه‌هایی را نشان می‌دهد که طبقه‌بند آن‌ها را به‌عنوان رده دوم (رده بیشینه) شناسایی می‌کند. ستون‌های ماتریس ابهام توزیع نمونه‌های رده را نشان می‌دهد. درحقیقت هر معیاری که از آن‌ها به‌طور هم‌زمان استفاده می‌کند، نمی‌تواند عاری از حساسیت نسبت به نبود تعادل رده باشد. برای مثال، معیار دقت از هر دو ستون استفاده می‌کند و بنابراین نسبت به نبود تعادل حساس است؛ یعنی با تغییردادن توزیع‌های ردهٔ مجموعه‌داده، این معیار ممکن است، تغییر کند؛ درحالی‌که عملکرد تغییر نکرده است. بعضی معیارهایی که برای ارزیابی عملکرد یادگیری در مجموعه‌داده‌های دارای دو رده یا مجموعه‌داده‌های نامتعادل تنظیم می‌شوند، عبارتند از: دقت، صراحت، فراخوانی.

دقت با استفاده از معادلات (۹ تا ۱۱) به‌دست می‌آید.

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (۹)$$

صحت با معادله (۱۰) به‌دست می‌آید.

$$PP = \frac{TP}{TP + FP} \quad (۱۰)$$

فراخوانی با معادله (۱۱) به‌دست می‌آید.

$$Sp = \frac{TP}{TP + FN} \quad (۱۱)$$

نمودارهای ترسیم‌شده در شکل (۱۰)، نمونه‌ای از ویژگی‌های آموزش داده‌شده را برای هر طبقه نشان می‌دهد. این شکل میانگین ضربان را از بانک اطلاعاتی MIT-BIH که به‌وسیلهٔ چهار ردهN ، $SVEB$ ، VEB وF طبقه‌بندی شده است، نشان می‌دهد. نمودارهای ترسیم‌شده در شکل (۱۰) به‌صورت زیر تشریح شده‌اند:

[Downloaded from jsdp.rcisp.ac.ir on 2026-09-15]

[DOI: 10.52547/jsdp.19.3.65]

(a) پنجره متمرکزشده در قله R از سیگنال خام ECG، (b) استخراج ویژگی‌های خطی از تبدیل ویولت گسسته با تابع پایه db6، نمودار شکل (c) بازه HOS برای چولگی و کشیدگی و نمودار شکل (d) هیستوگرام HOS و DWT.

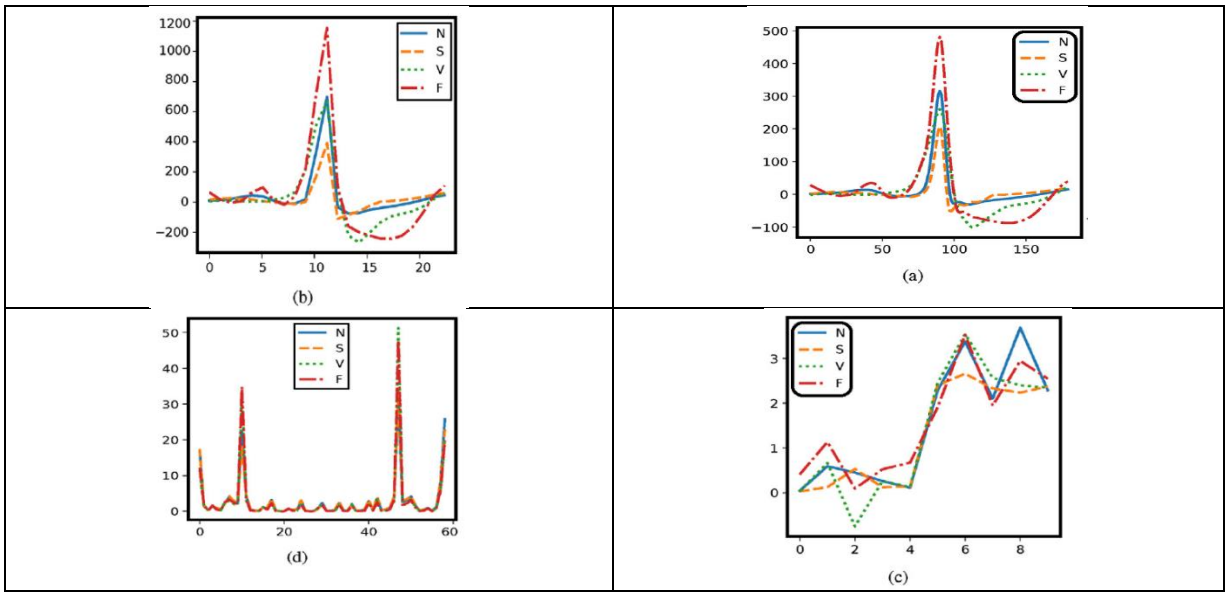

(شکل-۱۰): میانگین ضربان از بانک اطلاعاتی MIT-BIH که توسط چهار رده N، SVEB، VEBو F طبقه‌بندی شده است.

(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 مجموعه‌داده 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,coeficients	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%;
Prposed 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 cummulants; **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.

روش‌های مختلف به‌همراه ویژگی‌هایشان در جدول ۵ آورده شده است. جدول (۵) روش پیشنهادی را از نظر معیارهای مختلفی از جمله دقت، صحت، فراخوانی و نرخ مثبت درست با سایر روش‌های رقیب مقایسه کرده

[Downloaded from jsdp.rcisp.ac.ir on 2026-09-15]

[DOI: 10.52547/jsdp.19.3.65]

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 پشیبان چندهسته‌ای است). جدول (۷) روش پیشنهادی را از نظر 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 یا سایر روش‌های SVM مقایسه کرده و نشان داده شده که روش پیشنهادی برتری چشم‌گیری نسبت به سایر روش‌ها دارد.

(جدول-۶): دقت طبقه‌بندی با استفاده از ۵ روش طبقه‌بندی با انتخاب۴۰ ویژگی روی مجموعه‌داده 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
Prposed method	4.106	4.441	4.441

(جدول-۸): مقایسه دقت روش پیشنهادی با روش‌های با انتخاب ویژگی مختلف روی مجموعه‌داده 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

[Downloaded from jsdp.rcisp.ac.ir on 2026-09-15]

[DOI: 10.52547/jsdp.19.3.65]

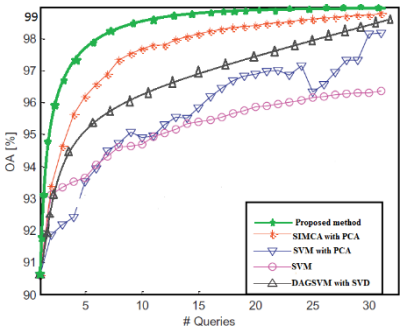

(شکل-۱۱): مقایسه روش‌های استفاده‌کننده از SVM بر روی پایگاه داده‌استاندارد MIT-BIH

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

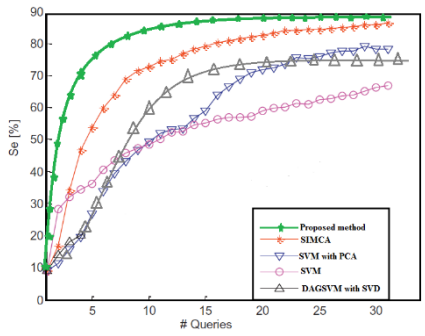

(شکل-۱۲): مقایسه روش‌های استفاده‌کننده از SVM بر روی پایگاه داده‌استاندارد INCART

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

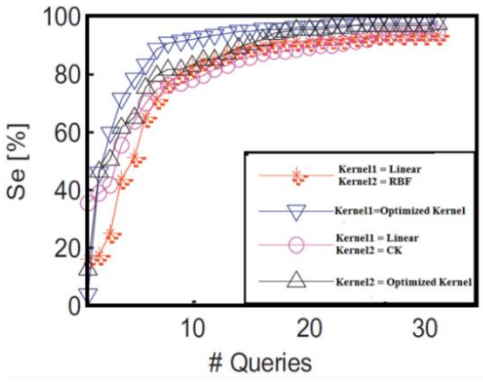

(شکل-۱۳): مقایسه روش پیشنهادی با هسته‌های مختلف و بهینه بر روی مجموعه‌داده استانداردMIT-BIH

(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 هسته-های غیرخطی باعث می‌شود تا نگاشت داده‌ها به عمق بالاتر بهتر انجام گیرد که نتیجه آن افزایش عملکرد طبقه‌بندی می‌شود. ازآن‌جایی‌که طبقه‌بند پیشنهادی 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.

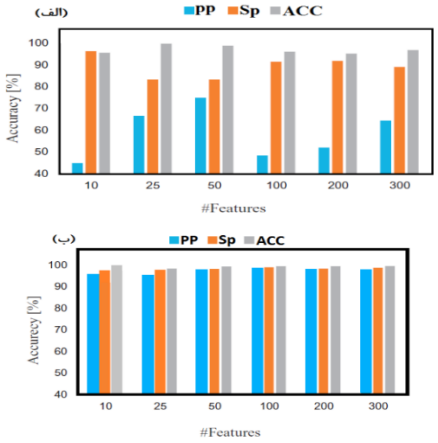

(شکل-۱۴): به کارگیری SVM را در (الف) حالت معمولی و در (ب) روش پیشنهادی از نظر دقت صحت و نرخ مثبت درست بر روی مجموعه داده SVDB

(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.

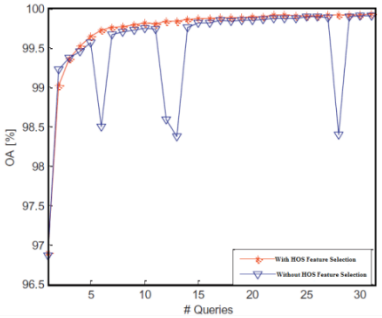

(شکل-۱۵): مقایسه روش پیشنهادی در دو حالت استفاده از HOS و بدون استفاده از HOS روی مجموعه‌داده استانداردMIT-BIH

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

[Downloaded from jsdp.rcisp.ac.ir on 2026-09-15]

[DOI: 10.52547/jsdp.19.3.65]

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 به‌کارگیری روش استخراج ویژگی با DWT دقت بالاتری را از خود نشان داده است.

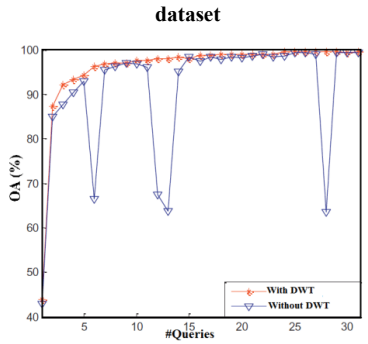

(شکل -۱۶): مقایسه روش پیشنهادی در دو حالت استفاده از DWT و بدون استفاده از DWT روی مجموعه‌داده استاندارد MIT-BIH

(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 به‌کارگیری روش استخراج ویژگی پیشنهادی دقت بالاتری را از خود نشان داده است.

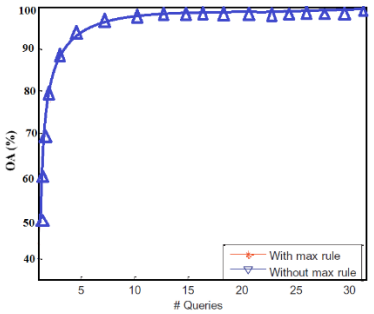

(شکل-۱۷): مقایسه روش پیشنهادی در دو حالت استفاده از DWT و HOS و بدون استفاده DWT و HOS روی مجموعه داده استانداردMIT-BIH

(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- نتیجه‌گیری

در این بخش به بررسی نتایج به‌دست‌آمده از اجرای روش پیشنهادی و مقایسه آن با روش‌های پیشین و درنهایت به جمع‌بندی و ارائه پیشنهاد، پرداخته خواهد شد.

در این پژوهش طبقه‌بندی آریتمی قلبی و سیگنال نرمال انتخاب‌شده بر روی سه مجموعه‌داده بررسی شده است. در این مدل ابتدا سعی در حذف انواع نوفه کرده و همچنین به‌کمک مدل آمیخته گوسی توانستیم ضربان‌های پرت را از سیگنال‌های ECG حذف کرده و سیگنال عاری از نوفه داشته باشیم. در این مدل همچنین برای افزایش دقت مدل و کاهش تعداد ویژگی‌های نامناسب از روش ترکیبی سیگنال‌های خطی و غیرخطی استفاده شده است. برای استخراج ویژگی‌های خطی از تبدیل ویولت گسسته با تابع پایه db6 استفاده شده و برای استخراج ویژگی‌های غیرخطی از higher order sperctra یا HOS استفاده شده است.

در انتخاب بهینه ویژگی، رویکردی مناسب جهت دست‌یابی به دو هدف است:

- افزایش دقت طبقه‌بندی
- انتخاب تعداد ویژگی کمتر (ویژگی‌های برتر)

انتخاب تعداد ویژگی‌کمتر باعث کاهش محاسبات خواهد شد و این درحالی است‌که با انتخاب تعداد ویژگی کمتر، دقت بهتری نسبت به حالتی که تمامی ویژگی‌ها به SVMs اعمال می‌شود، مشاهده شد. هم‌چنان که از نتایج حاصل‌شده در بخش قبل مشاهده شد، روش پیشنهادی که از مجمع ماشین‌های بردار پشتیبان استفاده کرده به‌طورکامل نسبت به سایر روش‌ها برتری دارد؛ بنابراین می‌توان نتیجه گرفت که از اجماع چندین طبقه‌بند SVM می‌توان با دقت قابل قبولی سیگنال ECG را طبقه‌بندی کرد؛ این در حالی است که بتوان اصل تنوع را برای آرای حاصله از خروجی هر طبقه‌بند ایجاد کرد. در این روش برای برقراری تنوع آرای حاصله از هر SVM از هسته‌های مختلف برای SVMها 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 روش‌های رقیب دقت بهتری را در طبقه‌بندی سیگنال ECG ارائه نموده است. همچنین در این روش برای افزایش دقت طبقه‌بندی، 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 طبقه‌بندی مؤثر واقع شده است. روش پیشنهادی برای به‌دست‌آوردن هسته‌های بهینه از الگوریتم بهینه‌سازی ژنتیک استفاده کرده است که این بهینگی هسته‌ها در افزایش دقت طبقه‌بندی نهایی مؤثر واقع شد. می‌توان درنهایت نتیجه گرفت که روش پیشنهادی با دقتی معادل ۹۹/۱۵ توانسته به‌خوبی سیگنال‌های ECG را طبقه بندی کند.

درنهایت، با توجه به نتایجی که از تحلیل برروی مجموعه‌داده جمع‌آوری‌شده به‌دست آورده شده، نکاتی

[Downloaded from jsdp.rcisp.ac.ir on 2026-09-15]

[DOI: 10.52547/jsdp.19.3.65]

جهت دست‌یابی به تشخیص بهتر بیماری قلبی پیشنهاد شده است:

- اضافه‌کردن 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 physioloy", 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 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 componentand 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 ProcessingSystems (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 (ICCMA)*,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. Zaunseder, J.P. Martínez, M. Llamedo, R. "Poll,Optimization of ECG classification by means of featureselection",

[Downloaded from jsdp.rcisp.ac.ir on 2026-09-15]

[DOI: 10.52547/jsdp.19.3.65]

[36] A. Khazaee, "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-Chil 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-BIHarrhythmia 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 computingwith 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 basedheartbeat classification using higher order statistics andhermite basis function", in: Comput. Cardiol., 2008, pp.229–232.

[27] P. de Chazal, M. O'Dwyer, R.B. Reilly, "Automaticclassification of heartbeats using ECG morphology andheartbeat interval features", *IEEE Trans*. Biomed. Eng. Vol.51 (7), pp.1196–1206, 2004.

[28] G. de Lannoy, D. Franc¸ois, J. Delbeke, M. Verleysen, "Weighted SVMs and feature relevance assessment insupervised heart beat classification", in: BiomedicalEngineering Systems and Technologies (BIOSTEC), pp.212–223, 2010.

[29] N. Ozcan, F. Gurgen, "Fuzzy support vector machines for ECGarrhythmia detection", *in: IEEE International Conference onPattern Recognition (ICPR)*, 2010, pp. 2973–2976.

[30] H. Huang, J. Liu, Q. Zhu, R. Wang, G. Hu, "A new hierarchicalmethod for inter-patient heartbeat classification usingrandom projections and RR intervals", Biomed. Eng. Online13, pp. 1–26, 2014.

[31] J.A. Nasiri, M. Naghibzadeh, H.S. Yazdi, B. Naghibzadeh, "ECG arrhythmia classification with support vectormachines and genetic algorithm", *in: IEEE EuropeanSymposium on Computer Modeling and Simulation (EMS)*, pp. 187–192, 2009.

[32] K. Polat, S. Günes¸, "Detection of ECG arrhythmia using adifferential expert system approach based on principalcomponent analysis and least square support vectormachine," *Appl. Math. Comput*, vol.186 (1), pp. 898–906, 2007.

[33] M. Moavenian, H. Khorrami, "A qualitative comparison ofartificial neural networks and support vector machines inECG 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 Machins ", *The 13th Irananin student* Electrical and Electronic Engineering Conference. 2010.

[Downloaded from jsdp.rcisp.ac.ir on 2026-09-15]

[DOI: 10.52547/jsdp.19.3.65]

[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. Llamedo, 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

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

[Downloaded from jsdp.rcisp.ac.ir on 2026-09-15]

[DOI: 10.52547/jsdp.19.3.65]

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

[Downloaded from jsdp.rcisp.ac.ir on 2026-09-15]

[DOI: 10.52547/jsdp.19.3.65]