انتخاب ویژگی برای تشخیص آریتمی‌های قلبی با استفاده از بهینه‌سازی ازدحام ذرات دودویی چندهدفه

مهسا واقفی*[1] و فاطمه جمشیدی[2]

[1]گروه مهندسی برق، واحد شیراز، دانشگاه آزاد اسلامی، شیراز، ایران

[2]گروه مهندسی برق، دانشکده مهندسی، دانشگاه فسا، فسا، ایران

چکیده

سیگنال الکتروکاردیوگرام، یکی از مهم‌ترین ابزار برای طبقه‌بندی انواع مختلف آریتمی‌های قلبی است. به‌طورمعمول سیگنال‌های ECG، حاوی نوفه‌های متفاوتی هستند. در این مقاله، تکنیک تجزیه مد تجربی گروهی که در آن هر تابع مد ذاتی (IMF)، شامل تنها یک مؤلفهٔ فرکانسی است، برای حذف نوفه به کار رفته است. با کمک پنجره‌بندی مناسب بر روی کمپلکس QRS متشکل از جمع سه IMF نخست، حذف نوفه با کمترین اعوجاج انجام شده و با استفاده از تبدیل موجک گسسته، نوفه‌های باقیمانده نیز از بین رفته، سپس با به‌کارگیری تجزیه بستهٔ موجک، از سیگنال ویژگی استخراج شده است که ویژگی‌های بهینه، با روش بهینه‌سازی ازدحام ذرات دودویی چندهدفه انتخاب شده‌اند؛ درنهایت از شبکه عصبی پس‌انتشار، برای طبقه‌بندی استفاده شده که مقدار دقت ۹۹/۱۲ درصد برای ۱۷ عدد سیگنال دریافت‌شده از پایگاه دادهٔ MIT-BIH، به‌دست آمده است.

واژگان کلیدی: الکتروکاردیوگرام؛ بهینه‌سازی ازدحام ذرات دودویی چندهدفه؛ تجزیه بستهٔ موجک؛ تجزیه مد تجربی گروهی؛ شبکه عصبی پس‌انتشار.

Features selection for cardiac arrhythmia diagnosis using multiple objective binary particle swarm optimization

Mahsa Vaghefi[1*] & Fatemeh Jamshidi[2]

[1] Department of Electrical Engineering, Shiraz Branch, Islamic Azad University, Shiraz, Iran.

[2] Department of Electrical Engineering, Fasa University, Fasa, Fars province, Iran.

Abstract

Any heart activity disorder may lead an irregularity in is rhythm, or cardiac arrhythmia. An ECG signal is one of the major tools for classifying different types of cardiac arrhythmias. ECG signals usually contain various noises. To have a better signal processing, it is essential to remove noises in a way that a signal structure never becomes subject to distortion. After the step of noise removal, selection of an appropriate method is of paramount importance for feature extraction. Optimal features can be selected to improve efficiency and reduce calculations. This article used the ensemble empirical mode decomposition (EEMD) in which any intrinsic mode function (IMF) contains only a single frequency component for noise removal. The noise removal operation with the least distortion is possible using an appropriate windowing on a QRS complex containing sum of the first three IMFs. Later, the remaining noises can be removed using discrete wavelet transform (DWT). The results of using the EEMD-DWT combined method were compared with EMD and DWT combination. After the noise removal step, feature extraction was performed through a wavelet packet decomposition. It is capable of signal decomposition at all frequencies. Multiple objective binary particle swarm optimization (MOBPSO) method was used to select optimal features and the effect of this method on the results was examined. Finally, the back propagation neural network (BPNN) and a support vector machine based on particle swarm optimization were used for classification. This article used 17 signals received from the MIT-BIH database. The acquired data belong to 6 different types of classes. After pre-processing, feature

* Corresponding author

*نویسندهٔ عهده‌دار مکاتبات

تاریخ ارسال مقاله: ۱۳۹۷/۱۱/۲۵ ●تاریخ پذیرش: ۱۳۹۹/۵/۲۸ ●تاریخ انتشار: ۱۴۰۰/۰۷/۱۷ ●نوع مطالعه: پژوهشی

[Downloaded from jsdp.rcisp.ac.ir on 2026-02-04]

[DOI: 10.52547/jsdp.18.2.163]

extraction, feature selection, and classification on the input data, it is observed that the proposed technique of EEMD-DWT is an appropriate method for noise removal and MOBPSO is a suitable method for the selection of best features. The BPNN classifier managed to classify cardiac arrhythmias with a higher accuracy and the values for accuracy, sensitivity, specificity, and positive predictive value were 99.12%, 97.08%, 99.38%, and 97.12%, respectively.

Keywords: Back Propagation Neural Network; Discrete Wavelet Transform; Electrocardiogram; Ensemble Empirical Mode Decomposition; Multiple Objective Binary Particle Swarm Optimization.

۱- مقدمه

سیگنال الکتروکاردیوگرام (ECG[1]) نمایش کاملی از فعالیت الکتریکی قلب روی سطح بدن انسان است و به‌طور گسترده در تشخیص بالینی بیماری‌های قلبی به‌کار می‌رود. الکتروکاردیوگرام طبیعی از یک موج P، یک کمپلکس QRS و یک موج T تشکیل شده است. کمپلکس QRS اغلب اما نه همیشه از سه موج جداگانه یعنی موج Q، موج R و موج S به وجود آمده است [۱].

نوفه‌ها همواره کیفیت سیگنال ECG را کاهش می‌دهند. از آنجا که این سیگنال غیرایستا است، حذف نوفه از آن، همواره کار سختی است. منابع نوفه ممکن است قلبی یا غیر قلبی باشند. ازجمله منابع نوفه قلبی می‌توان به کاهش یا ناپدیدشدن فاصلهٔ ایزوالکتریک، طولانی‌شدن رپولاریزاسیون و لرزش دهلیز اشاره کرد. تنفس، تغییر موقعیت الکترودها، انقباض ماهیچه‌ها و تداخل خط تغذیه، جزء منابع نویز غیر قلبی به شمار می‌روند. هر روش حذف نوفه‌ای که کمترین تلفات اطلاعات و در عین حال سطح رضایت‌بخشی از حذف نوفه را به همراه داشته باشد، می‌تواند به‌خوبی به کیفیت و در نتیجه تشخیص و آنالیز سیگنال، کمک کند [2]. روش‌های بی‌شماری جهت حذف نوفه بر روی سیگنال‌های الکترکاردیوگرام وجود دارند که می‌توان به ترکیب تجزیه مد تجربی (EMD[2]) و تبدیل موجک گسسته (DWT[3]) [3]، تکنیک تجزیه مد تجربی گروهی (EEMD[4]) [4]، فیلتر وفقی [5]، تبدیل موجک گسسته [6]، فیلتر وفقی مبتنی بر الگوریتم بهینه‌سازی ازدحام ذرات اصلاح‌شده اشاره کرد. در این مقاله به‌وسیلهٔ ترکیب EEMD و DWT، نوفه موجود در سیگنال ECG حذف شده است.

پس از مرحلهٔ حذف نوفه، نوبت به استخراج ویژگی می‌رسد. بهبود روش‌های سریع و دقیق، برای استخراج ویژگی‌های ECG، به‌خصوص جهت بررسی داده‌های ضبط‌شدهٔ طولانی، از اهمیت بالایی برخوردار است. روش‌های پیشنهادی آنالیز سیگنال ECG در ابتدا بر اساس روش‌های حوزهٔ زمان بنا نهاده شده بودند؛ اما این روش‌ها برای مطالعهٔ این سیگنال، کافی نبودند؛ بنابراین نمایش فرکانسی سیگنال نیز ضرورت پیدا کرد [8]. پژوهش‌گران، انواع مختلفی از ویژگی‌ها همچون ویژگی‌های مبتنی بر شاخص‌های آماری مرتبهٔ بالاتر [9]، تبدیل موجک [10]، تبدیل فوریه [11]، ویژگی‌های ریخت شناسی [12]، توابع هرمیت [13]، ویژگی‌های حوزه فرکانس [14] و آنالیز مؤلفهٔ اساسی [15] را برای این سیگنال استفاده کرده‌اند. در این مقاله، ویژگی‌های آماری مربوط به ضرایب تجزیهٔ بستهٔ موجک (WPD[5]) مثل مقدار بیشینه، انحراف معیار و مقدار تکین، استخراج شده است.

در راستای بهبود راندمان و کاهش محاسبات، می‌توان ویژگی‌های اضافی را حذف کرد. بدین منظور تاکنون الگوریتم‌های مختلفی مانند الگوریتم ژنتیک [16]، جستجوی مستقیم ترتیبی [17]، ترکیب بهینه‌سازی ازدحام ذرات (PSO[6]) و کرم شب‌تاب [18]، آنالیز مؤلفهٔ اساسی و تکنیک تفکیک‌کننده خطی [19] پیشنهاد شده است. در این مقاله از الگوریتم بهینه‌سازی ازدحام ذرات دودویی چندهدفه (MOBPSO[7])، جهت انتخاب بهترین ویژگی‌ها به کار رفته است.

روش‌های مختلفی برای طبقه‌بندی‌کردن سیگنال‌های ECG همچون شبکه عصبی پس‌انتشار (BPNN[8]) [20]، سیستم استنتاج عصبی-فازی سازگار (ANFIS)[9] [21]، ماشین بردار پشتیبان (SVM)[10] [22]، K نزدیک‌ترین همسایه [23]، درخت تصمیم‌گیری [24]، شبکه‌های عصبی پیچشی [25] و جنگل تصادفی (RF)[11] [26] پیشنهاد شده است. در این مقاله، از SVM مبتنی بر PSO (PSO-SVM) و BPNN، جهت طبقه‌بندی به‌کار رفته است.

در ادامه و در بخش دوم مقاله، الگوریتم‌های EMD، EEMD، DWT، WPD، MOBPSO، PSO-SVM و BPNN توضیح داده شده است. در بخش سوم، الگوریتم

[1] Electrocardiogram
[2] Empirical Mode Decomposition
[3] Discrete Wavelet Transform
[4] Ensemble Empirical Mode Decomposition
[5] Wavelet Packet Decomposition
[6] Particle Swarm Optimization
[7] Multiple Objective Binary Particle Swarm Optimization
[8] Back Propagation Neural Network
[9] Adaptive Neuro-Fuzzy Inference System
[10] Support Vector Machine
[11] Random Forest

[Downloaded from jsdp.rcisp.ac.ir on 2026-02-04]
[DOI: 10.52547/jsdp.18.2.163]

پیشنهادی و نتایج شبیه‌سازی حاصل از آن و در بخش چهارم، بحث و نتیجه‌گیری آورده شده است.

۲- روش کار

به‌طور کلی مراحل انجام کار شامل؛ اکتساب سیگنال، حذف نوفه، استخراج ویژگی، انتخاب ویژگی و طبقه‌بندی است (شکل (۱)) که به‌ترتیب در ادامه شرح داده شده است.

در ابتدا به‌کمک تکنیک EEMD، کمپلکس QRS عاری از نوفه می‌شود؛ سپس توسط DWT و به‌کمک آستانه‌سازی نرم، به کاهش بیشتر نوفه، به‌خصوص در قسمت‌های دیگر سیگنال پرداخته می‌شود.

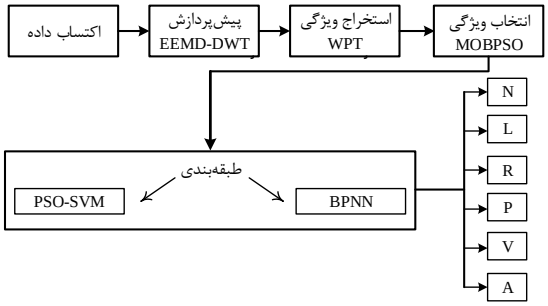

(شکل-۱): الگوریتم پیشنهادی جهت دسته‌بندی آریتمی‌های قلبی

(Figure-1): The proposed algorithm for the classification of cardiac arrhythmia

پس از حذف نوفه، نوبت به مرحله استخراج ویژگی می‌رسد. در مرحلهٔ استخراج ویژگی، WPD به کار گرفته شده است. به این صورت که سه مشخصهٔ آماری، برای هر سیگنال محاسبه می‌شود. جهت کاهش ابعاد ماتریس ویژگی‌ها و در راستای افزایش سرعت پردازش در مرحله بعد از MOBPSO برای انتخاب ویژگی‌های برتر استفاده شده است. مرحله آخر، طبقه‌بندی اطلاعات در شش ردهٔ متفاوت است که جهت طبقه‌بندی، الگوریتم BPNN و PSO-SVM به کار رفته است.

۲-۱- اکتساب داده

در این مقاله از پایگاه داده آریتمی MIT-BIH [27] استفاده شده است. تعداد هفده عدد فایل داده، شامل سیگنال‌های مربوط به افراد نرمال و افراد دارای بیماری قلبی مورد بررسی قرار گرفته است که سه فایل مربوط به افراد سالم و چهارده فایل به افراد دارای آریتمی قلبی اختصاص دارد و فرکانس نمونه‌برداری ۳۶۰ هرتز است. سیگنال‌های ECG به شش نوع ضربان نرمال (N)، ضربان انسداد شاخهٔ دستهٔ چپ (L)، ضربان انسداد شاخهٔ دستهٔ راست (R)، ضربان گام (P)، ضربان دهلیزی پیش از موقع (A) و انقباضات بطنی پیش از موقع (V) طبقه‌بندی شده‌اند. در جدول (۱) مشخصات سیگنال‌های اکتسابی آورده شده است. هر سیگنال به قطعه‌های هزارنقطه‌ای که تنها شامل کمپلکس‌های مورد نظر است، تفکیک و با کنار هم گذاشتن این قطعه‌ها، سیگنال نهایی آمادهٔ پیش‌پردازش می‌شود. به‌جز آریتمی نوع V، مابقی طبقات هر کدام شامل سه سیگنال هستند. با درنظرگرفتن این نکته، تعداد قطعات هر رده شصت قطعه و با توجه به آن‌که شش نوع ردهٔ مختلف در نظر گرفته شده، درمجموع، ۳۶۰ قطعه به‌دست آمده است؛ بنابراین هر کدام از داده‌های ۱۰۶ و ۲۲۳، ۳۰ قطعه‌ای و ۱۵ داده باقیمانده هر کدام ۲۰ قطعه‌ای انتخاب می‌شوند.

۲-۲- حذف نوفه

حذف نوفه از سیگنال‌های قلبی، یکی از مهم‌ترین موضوعات مقاله‌های حوزهٔ مهندسی پزشکی است. در این مقاله با ترکیب دو روش EEMD و DWT، حذف نوفه از سیگنال ECG صورت گرفته است. در ادامه توضیحاتی از روش EMD، EEMD، DWT و روش EEMD-DWT آورده شده است.

(جدول-۱): مشخصات سیگنال‌های اکتسابی

(Table-1): Specifications of acquired signals

ردیف	نوع سیگنال	شماره داده	تعداد قطعات	ردیف	نوع سیگنال	شماره داده	تعداد قطعات
۱	N	۱۰۰	۲۰	۱۰	P	۱۰۲	۲۰
۲		۱۰۵	۲۰	۱۱		۱۰۷	۲۰
۳		۲۱۵	۲۰	۱۲		۲۱۷	۲۰
۴	L	۱۰۹	۲۰	۱۳	A	۲۰۷	۲۰
۵		۱۱۱	۲۰	۱۴		۲۰۹	۲۰
۶		۲۱۴	۲۰	۱۵		۲۳۲	۲۰
۷	R	۱۱۸	۲۰	۱۶	V	۱۰۶	۳۰
۸		۱۲۴	۲۰	۱۷		۲۲۳	۳۰
۹		۲۱۲	۲۰	مجموع	۶ کلاس	۱۷ داده	۳۶۰ قطعه

[Downloaded from jsdp.rcisp.ac.ir on 2026-02-04]

[DOI: 10.52547/jsdp.18.2.163]

۱-۲-۲- تجزیه مد تجربی

تجزیه مد تجربی (EMD) نخستین‌بار در سال ۱۹۹۶، معرفی شد. تجزیه مد تجربی با توابع پایه‌ای تماماً منتج‌شده از داده، هم‌ذات و سازگار است. محاسبات EMD، به مقادیر از قبل شناخته‌شدهٔ سیگنال، احتیاجی ندارد. وظیفهٔ کلیدی تکنیک یادشده به این صورت است که ابتدا به‌طور تجربی، مدهای نوسانی در سیگنال را بر اساس مقیاس‌های زمانی مشخصات آنها تعیین می‌کند و سپس به تجزیهٔ سیگنال به توابع مد ذاتی می‌پردازد. EMD برای سیگنال‌های غیرایستا و غیرخطی مثل ECG، کاربرد دارد. یک تابع می‌تواند توابع مد ذاتی (IMF[1]) باشد، اگر دو شرط زیر را برآورده کند [2]:

۱- در تمام دادگان، تعداد نقاط اکسترمم محلی و صفرهای سیگنال، باهم برابر باشند یا بیشینه اختلافشان در تعداد، یک باشد.

۲- در هر نقطه، مقدار متوسط پوش[2] تعریف‌شده به‌وسیلهٔ بیشینه و کمینه محلی، صفر باشد.

در ادامه روش اصولی جهت تجزیهٔ سیگنال مورد نظر به توابع مد ذاتی که به فرآیند غربال‌گری[3] مشهور است، به‌ترتیب زیر شرح داده می‌شود:

الف- همهٔ بیشینه‌های محلی داده مشخص و به‌وسیلهٔ خطوطی به همدیگر وصل می‌شوند که پوش بالایی سیگنال شکل می‌گیرد.

ب- همین‌طور کمینه‌های محلی داده تعیین و به وسیلهٔ خطوط به همدیگر متصل و پوش پایینی سیگنال ایجاد می‌شود.

ج- در فرآیند غربال‌گری، ابتدا متوسط (m_1) پوش بالایی و پایینی سیگنال، تعیین و سپس این میانگین، از سیگنال اصلی ($x[n]$) کم می‌شود. حاصل تفریق، مؤلفهٔ اول ($h_1[n]$) نام دارد.

$$h_1[n] = x[n] - m_1 \qquad (۱)$$

اگر $h_1[n]$ شرایط IMF بودن را داشته باشد، به‌عنوان نخستین تابع مد ذاتی انتخاب می‌شود.

د – درصورتی‌که $h_1[n]$ شرایط IMF بودن را نداشت، آن‌گاه این مؤلفه به‌عنوان داده در نظر گرفته شده و بر روی آن فرآیند غربال‌گری دوم انجام می‌شود. درواقع تحت این شرایط، مراحل (الف) تا (ج) بر روی $h_1[n]$ انجام و مؤلفهٔ دوم یعنی $h_2[n]$ استخراج می‌شود.

$$h_2[n] = h_1[n] - m_2 \qquad (۲)$$

m_2 مقدار متوسط حاصل از $h_1[n]$ است. اگر $h_2[n]$ شرایط IMF بودن را برآورده نکرد، می‌توان از شرط انحراف استاندارد (SD[4]) استفاده کرد. انحراف استاندارد از نتایج غربال‌گری متوالی یعنی $h_{i-1}[n]$ و $h_i[n]$ طبق معادلهٔ (۳) به‌دست می‌آید:

$$\mathrm{SD} = \sum_{n=0}^{N} \frac{|h_{i-1}[n]-h_i[n]|^2}{h_{i-1}^2[n]} \qquad (۳)$$

هنگامی که مقدار انحراف استاندارد، به کمتر از مقدار از پیش تعیین‌شده رسید، فرآیند غربال‌گری متوقف و $h_i[n]$ به‌عنوان اولین IMF انتخاب می‌شود. به‌طورمعمول نخستین IMF را با عبارت $C_1[n]$ نشان می‌دهند. در معادله (۳)، i و $i-1$، نشان‌دهندهٔ اندیس دو فرآیند غربال‌گری متوالی است.

ن- در این مرحله، نخستین IMF حاصل از مرحلهٔ قبل، از سیگنال اصلی کم شده و با باقی‌مانده ($r_1[n]$) همانند یک سیگنال جدید، رفتار می‌شود:

$$r_1[n] = x[n] - c_1[n] \qquad (۴)$$

بنابراین فرآیند غربال‌گری بر روی سیگنال $r_1[n]$ جهت رسیدن به باقیمانده جدید $r_2[n]$ ادامه می‌یابد. در حالت کلی می‌توان رابطهٔ (۵) را برای آن نوشت:

$$r_j[n] = x_{j-1}[n] - c_j[n] \qquad (۵)$$

اگر $r_j[n]$ یک تابع ثابت یا یکنواخت شده باشد، فرآیند تجزیهٔ سیگنال به توابع مد ذاتی به اتمام خواهد رسید. در معادله (۶)، سیگنال $x[n]$ که به L سطح IMF تجزیه شده، آورده شده است.

$$x[n] = \sum_{i=0}^{L-1} c_i[n] + r_L[n] \qquad (۶)$$

۲-۲-۲- تجزیه مد تجربی گروهی

عیب روش EMD پدیده‌ای به نام اختلاط مد است که در آن چند نوسان مختلف در یک مد و یا نوسانات مشابه در مدهای مختلف، اتفاق می‌افتد. روش تجزیه مد تجربی گروهی (EEMD) این مشکل را با اضافه‌کردن نوفه گوسی سفید به تعداد بالا، حل می‌کند. درواقع این نوفه سفید اضافه‌شده به سیگنال ECG، طیف وسیعی از منابع مختلف نوفه تصادفی را که در محدودهٔ گسترده‌ای از فرکانس‌ها و با نسبت‌های مختلف سیگنال به نوفه هستند، نشان می‌دهد [28]. الگوریتم کلی روش EEMD را

[1] Intrinsic Mode Functions
[2] Envelope
[3] Sifting
[4] Standard Deviation

[Downloaded from jsdp.rcisp.ac.ir on 2026-02-04]
[DOI: 10.52547/jsdp.18.2.163]

می‌توان به این صورت بیان کرد که ابتدا به سیگنال اصلی تعداد M بار (M عدد صحیح مثبت)، نوفه سفید به‌صورت تصادفی اضافه می‌شود؛ سپس بر روی هر کدام از M سیگنال جدید، روش EMD اجرا، مدها استخراج و میانگین مدهای M سیگنال محاسبه می‌شوند که با اجرای این روش، مسألهٔ اختلاط مد دیگر اتفاق نمی‌افتد [4]. در شکل (۲) توابع مد ذاتی EEMD برای یک نمونه سیگنال ECG نشان داده شده است.

۳-۲-۲- تبدیل موجک گسسته

در روش تبدیل موجک گسسته (DWT)، سیگنال مورد نظر، آنالیز و به‌صورت ترکیب خطی از مجموع حاصل ضرب ضرائب موجک و موجک مادر، بیان می‌شود. تبدیل موجک گسسته، سیگنال را به اطلاعات تقریبی و جزئی تجزیه می‌کند تا بدین وسیله بتواند آن را در باندهای فرکانسی مختلف و با تفکیک‌پذیری متفاوت آنالیز کند [2].

۴-۲-۲- حذف نوفه با روش EEMD-DWT

در روش‌های سنتی حذف نوفه به‌کمک EEMD، پس از تجزیهٔ سیگنال، بر روی هر IMF، به‌وسیلهٔ آستانه‌سازی اقدام به حذف نوفه می‌شود [28]. از آنجا که فرکانس کمپلکس QRS و نوفه‌های فرکانس بالا به هم نزدیک هستند، با روش آستانه‌سازی نمی‌توان آنها را به‌خوبی از هم تمیز و اقدام به حذف نوفه کرد. در این مقاله، حذف نوفه به شکل سنتی انجام نشده است. در ادامه جزئیات مراحل کاهش نوفه از سیگنال الکتروکاردیوگرام ($s[n]$) به‌وسیلهٔ تکنیک EEMD، آورده شده است:

۱- مکان پیک R در سیگنال الکتروکاردیوگرام نوفه‌ای مشخص می‌شود.

۲- توسط روش EEMD، توابع مد ذاتی به‌دست می‌آیند.

۳- حاصل جمع IMF اول تا IMF سوم ($d[n]$) و حاصل جمع IMF چهارم تا IMF دوازدهم ($r[n]$) به‌دست می‌آید.

۴- سری‌های زمانی $d[n]$ و $r[n]$ از پنجرهٔ توکی [2] عبور داده و به‌ترتیب سری‌های زمانی $d_2[n]$ و $r_2[n]$ ایجاد می‌شوند. طول پنجره، کمپلکس QRS حاصل از سه IMF نخست را پوشش می‌دهد و مرکز پنجره منطبق با مکان پیک R در نظر گرفته شده است.

۵- سه سری زمانی $r[n]$ و $d_2[n]$ و $r_2[n]$ با یکدیگر جمع و سیگنال بازسازی‌شده $s_2[n]$ ساخته می‌شود.

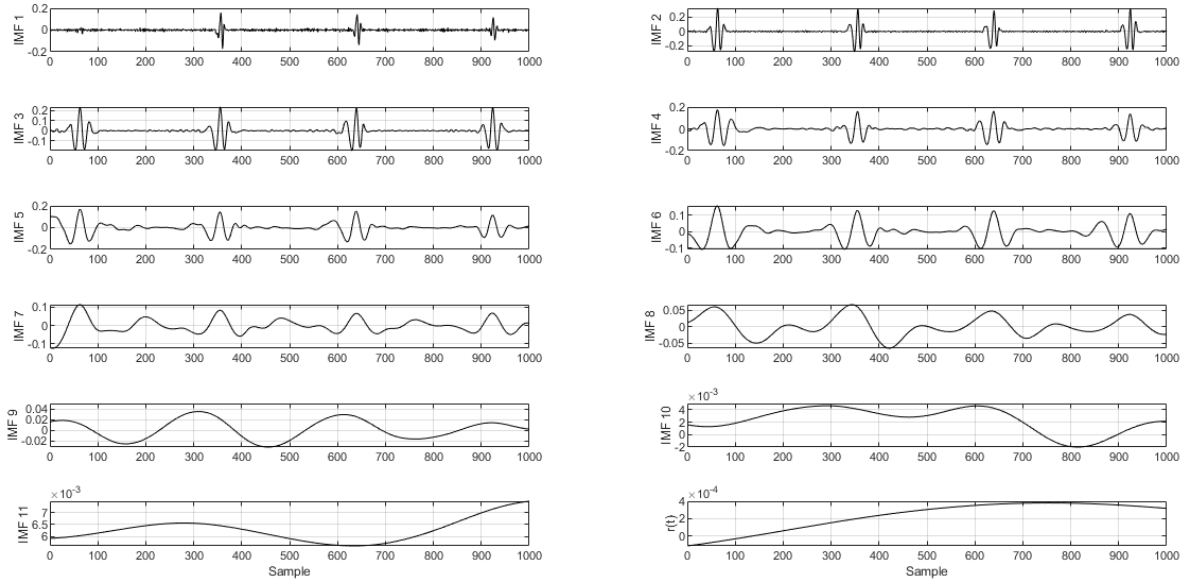

(شکل-۲): تجزیه سیگنال ECG توسط الگوریتم EEMD

(Figure-2): ECG signal decomposition by EEMD algorithm

پس از کاهش نوفه سیگنال الکتروکاردیوگرام به روش EEMD، جهت هرچه بهترکردن کیفیت سیگنال، از DWT نیز استفاده می‌شود. $s_2[n]$، به‌عنوان سیگنال ورودی DWT انتخاب شده و بر روی آن عملیات تجزیه، حذف نوفه به روش‌های آستانه‌سازی و سپس بازسازی سیگنال صورت می‌گیرد. آستانه‌سازی بر روی ضرائب جزئی تبدیل موجک که شامل فرکانس‌های بالای سیگنال الکتروکاردیوگرام است، انجام می‌گیرد. از طرفی چون ECG یک سیگنال غیرایستا است، استفاده از حد آستانهٔ ثابت توصیه نمی‌شود؛ بنابراین برای حذف نوفه مؤثر، روش

[Downloaded from jsdp.rcisp.ac.ir on 2026-02-04]
[DOI: 10.52547/jsdp.18.2.163]

حد آستانهٔ وفق‌شده با ضرایب جزئی در هر سطح، به کار برده شده است. حد آستانهٔ وفقی، طبق معادلهٔ (۷) به‌دست می‌آید [29]:

$$\delta(l) = \frac{median(|C(l)|)}{0.6745}\sqrt{2\log(M(l))} \qquad (۷)$$

که $\delta(l)$، $C(l)$ و $M(l)$ به‌ترتیب حد آستانه، ضریب جزئی سیگنال و طول بردار ضریب جزئی در سطح l را نشان می‌دهند. بین آستانه‌سازی‌های نرم و سخت، آستانه‌سازی نرم به‌دلیل عملکرد بهتر، انتخاب شده که آستانه‌سازی نرم وفقی، به‌صورت معادلهٔ (۸) قابل بیان است:

$$\hat{X}_d(l) = THR\big(\tilde{X}_d(l), \delta(l)\big), \quad l = 1,2 \qquad (۸)$$

که $\hat{X}_d$ به معنی آرایه‌ای از ضرایب جزئی DWT آستانه‌سازی شده است. در این مقاله، سیگنال دریافت‌شده در خروجی روش EEMD ($s_2[n]$) تا ۲ سطح، تجزیه و حذف نوفه می‌شود. ضرایب تبدیل موجک پس از حذف نوفه، طبق رابطهٔ (۹) کنار هم مرتب می‌شوند:

$$\hat{X} = [\hat{X}_d(1) \;\; \hat{X}_d(2) \;\; \hat{X}_a(2)] \qquad (۹)$$

$\hat{X}_d(1)$ و $\hat{X}_d(2)$ ضرائب جزئی سطح نخست و دوم و $\hat{X}_a(2)$، ضریب تقریبی سطح دوم تبدیل موجک است. سرانجام توسط تبدیل موجک معکوس، تخمینی از سیگنال ECG اصلی به‌دست خواهد آمد. تأکید می‌شود که آستانه‌سازی نرم وفقی، تنها بر روی ضرائب جزئی اعمال می‌شود. این انتخاب به‌دلیل آن است که نوفه‌های فرکانس بالا در ضرایب جزئی تبدیل موجک خودنمایی می‌کنند. خانوادهٔ سیملت نسبت به سایر موجک‌های مادر، جزئیات بیشتر و دقیق‌تری را نشان می‌دهد. همچنین این خانواده، شباهت زیادی به کمپلکس QRS دارد [2]. در این مقاله، سیملت هفت به‌عنوان موجک مادر در نظر گرفته شده است. در شکل (۳) یک نمونه سیگنال ECG حذف نوفه‌شده به‌وسیلهٔ روش EEMD-DWT در مقایسه با روش EMD-DWT نشان داده شده است.

۳-۲- استخراج ویژگی

روش‌های مختلفی جهت استخراج ویژگی از یک سیگنال وجود دارد. در این جا، ویژگی‌های آماری مربوط به ضرایب WPD یعنی مقدار بیشینه، انحراف معیار و تکین مورد استفاده قرار گرفته و در ادامه WPD و تشکیل ماتریس ویژگی توضیح داده شده است.

۳-۲-۱- تجزیهٔ بستهٔ موجک

تجزیهٔ بستهٔ موجک (WPD)، ابزار مفیدی جهت تحلیل و استخراج اطلاعات از سیگنال الکتروکاردیوگرام است. درواقع این روش تعمیمی از تبدیل موجک است. در تبدیل موجک با استفاده از فیلتر بانک‌ها، سطح تجزیه در فرکانس‌های پایین اتفاق می‌افتد و باند فرکانس بالا به سطوح پایین‌تر تجزیه نمی‌شوند، اما در WPD نه‌تنها یک تفکیک‌پذیری دقیقی در فرکانس‌های پایین (تقریب‌ها) وجود دارد، بلکه در فرکانس‌های بالا (جزئیات) نیز تفکیک‌پذیری خوبی مشاهده می‌شود. قدرت تفکیک‌پذیری سیگنال ECG در فرکانس‌های بالا و پایین به‌وسیلهٔ WPD، باعث طبقه‌بندی بهتر سیگنال خواهد شد [30].

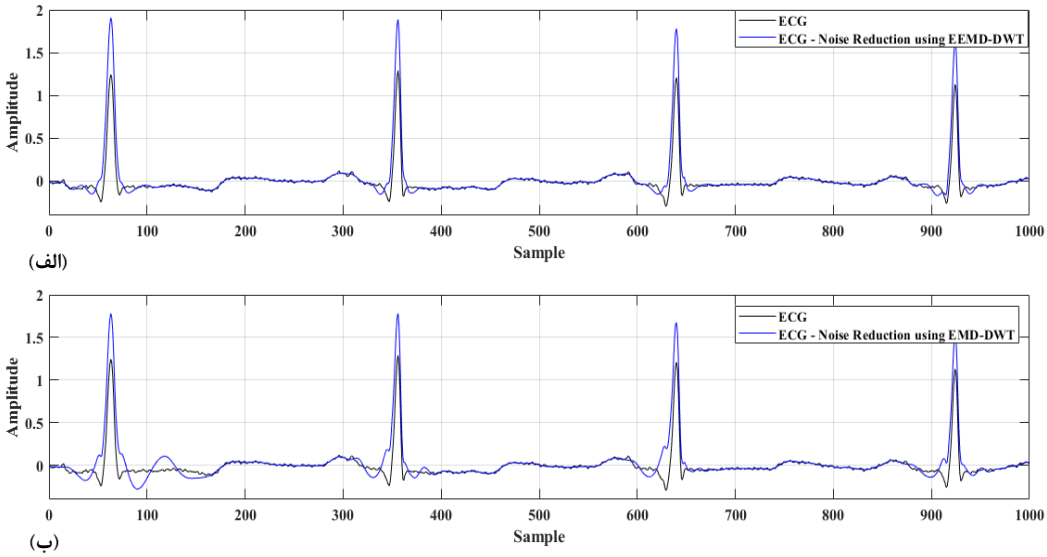

(شکل-۳): کاهش نوفه با استفاده از (الف) الگوریتم EEMD-DWT (ب) الگوریتم EMD-DWT

(Figure-3): Noise reduction using the (a) EEMD-DWT algorithm (b) EMD-DWT algorithm

[Downloaded from jsdp.rcisp.ac.ir on 2026-02-04]
[DOI: 10.52547/jsdp.18.2.163]

۲-۳-۲- تشکیل ماتریس ویژگی

مرحلهٔ استخراج ویژگی به روش WPD آماری صورت گرفته است. در ابتدا به‌علت بالابودن قدرت تفکیک‌پذیری فرکانسی WPD، سیگنال ECG حذف نوفه‌شده تا چهار سطح تجزیه می‌شود؛ سپس ضرایب سطح چهارم هر قطعه از سیگنال که به تعداد شانزده عدد است، جهت استخراج ویژگی انتخاب می‌شود. برای هر سیگنال، ویژگی‌های آماری شامل مقدار بیشینه، انحراف معیار و مقدار تکین از ضرایب WPD محاسبه می‌شود. با توجه به سه ویژگی آماری بالا و شانزده ضریب سطح چهار، تبدیل موجک برای هر قطعهٔ هزار نقطه‌ای سیگنال، ویژگی‌های هر قطعه، شامل ۴۸ (۳×۱۶) بعد خواهد بود. از سویی دیگر، همان‌گونه که در قسمت قطعه‌بندی دیده شد، تعداد ۳۶۰ قطعه از کل سیگنال‌ها، به‌دست آمد و چون هر قطعه، ۴۸ ویژگی دارد، پس در مجموع، یک ماتریس ۴۸×۳۶۰ حاصل می‌شود که عدد ۴۸ بیان‌گر تعداد ویژگی‌ها و ۳۶۰ نشان‌دهندهٔ تعداد مشاهدات یا نمونه‌های هزار نقطه‌ای است. در این مقاله موجک مادر دابشیز شش در نظر گرفته شده است.

پس از محاسبهٔ ویژگی‌های آماری، دیده می‌شود که اندازهٔ هر کدام از آنها، متفاوت و پراکندگی زیادی نسبت به هم دارند. به همین منظور، برای متمرکزکردن ویژگی‌های استخراج‌شده، مطابق رابطهٔ (۱۰)، بین صفر و یک، نرمالیزه شده‌اند:

$$N_{FE}(i) = \frac{(FE(i) - \min(FE))}{(\max\ (FE) - \min(FE))} \qquad (۱۰)$$

FE ویژگی استخراج شده، $\min(FE)$ کوچک‌ترین و $\max\ (FE)$ بزرگ‌ترین مقدار ویژگی استخراج‌شده، N_{FE} ویژگی نرمالیزه‌شده و i بیان‌گر شمارهٔ ویژگی مورد نظر است.

۲-۴- انتخاب ویژگی

انتخاب ویژگی، یکی از مراحل استخراج ویژگی‌ها به‌شمار می‌رود. به‌طورمعمول به‌وسیلهٔ الگوریتم‌های مختلفی می‌توان ویژگی‌های مؤثر را انتخاب و مابقی ویژگی‌ها را حذف کرد. ویژگی‌های انتخاب‌شده، می‌بایست به‌گونه‌ای فیلتر شوند که نتایج طبقه‌بندی خوبی را به همراه داشته باشند. از جمله مزایای کاهش ویژگی‌ها، بالارفتن سرعت پردازش در طبقه‌بندی سیگنال‌ها است. در ادامه، الگوریتم بهینه‌سازی ازدحام ذرات دودویی چندهدفه شرح داده شده است.

۲-۴-۱- بهینه‌سازی ازدحام ذرات دودویی چندهدفه

بهینه‌سازی ازدحام ذرات (PSO) به‌سبب سادگی و محاسبات کم یکی از پرکاربردترین الگوریتم‌های ابتکاری است. PSO الهام‌گرفته از رفتار اجتماعی دسته پرندگان است. PSO از تعدادی ذره (جواب نامزد) استفاده می‌کند که در فضای جستجو پرواز می‌کنند تا بهترین جواب را بیابند. موقعیت k امین درایهٔ ذره i در تکرار t، $x_i^k(t)$، سرعت k امین درایهٔ ذره i در تکرار t، $v_i^k(t)$، k اُمین درایهٔ بهترین جواب شخصی ذره i، $pbest_i^k$ و k اُمین درایهٔ بهترین جواب مطلق، $gbest^k$، برای تعیین موقعیت k اُمین درایهٔ ذره i در تکرار بعدی به شکل رابطه زیر است:

$$v_i^k(t+1) = wv_i^k(t) + c_1 \times rand \times \left(pbest_i^k - x_i^k(t)\right) + c_2 \times rand \times \left(gbest^k - x_i^k(t)\right) \qquad (۱۱)$$

$$x_i^k(t+1) = x_i^k(t) + v_i^k(t+1) \qquad (۱۲)$$

که w تابع وزن، c_1 و c_2 ضرایب شتاب، $rand_1$ و $rand_2$ اعداد تصادفی بین ۰ و ۱ هستند. در رابطه (۱۱)، $wv_i^k(t)$، $c_1 \times rand \times \left(pbest_i^k - x_i^k(t)\right)$ و $c_2 \times rand \times \left(gbest^k - x_i^k(t)\right)$ به‌ترتیب نشان‌دهنده قابلیت اکتشاف PSO، تفکر شخصی و همکاری ذرات است.

مراحل کلی الگوریتم PSO به شرح زیر است: ۱) تمام ذرات با مقادیر تصادفی مقداردهی اولیه می‌شوند. ۲) مراحل ۳ و ۴ تا برآورده‌شدن شرط خاتمه تکرار می‌شود. ۳) برای همه ذرات، سرعت به‌وسیلهٔ رابطه (۱۱) تعریف می‌شود. ۴) بردارهای موقعیت طبق رابطه (۱۲) به‌روز می‌شود.

مسایل زیادی مانند انتخاب ویژگی و کاهش بعد وجود دارد که به‌طور ذاتی فضای جستجوی دودویی گسسته دارند. PSO باینری (BPSO)[1] برای حل مسایل دودویی معرفی شده است. در BPSO، موقعیت یک ذره با احتمال سرعت آن تغییر می‌کند و به‌روزرسانی موقعیت به معنای تعویض مقادیر "۰" و "۱" است. برای انجام این کار، تابع‌تبدیل، $T\left(v_i^k(t+1)\right)$، برای نگاشت مقادیر سرعت به مقادیر احتمال لازم است. خانواده توابع تبدیل S شکل و V شکل، مطابق جدول (۲) برای این منظور تعریف شده‌اند.

[1] Binary Particle Swarm Optimization

[Downloaded from jsdp.rcisp.ac.ir on 2026-02-04]
[DOI: 10.52547/jsdp.18.2.163]

مراحل کلی الگوریتم BPSO به شرح زیر است: ۱) تمام ذرات با مقادیر تصادفی مقداردهی اولیه می‌شوند. ۲) مراحل ۳ تا ۵ تا برآورده‌شدن شرط خاتمه تکرار می‌شود. ۳) برای همه ذرات، سرعت به‌وسیلهٔ رابطه (۱۱) تعریف می‌شود. ۴) احتمال تغییر درایه‌های بردارهای موقعیت به‌وسیلهٔ یکی از توابع تبدیل S شکل یا V شکل، محاسبه می‌شود. ۵) درایه‌های بردارهای موقعیت طبق رابطه (۱۳) برای توابع تبدیل S شکل و طبق رابطه (۱۴) برای توابع تبدیل V شکل به‌روز می‌شود:

$$x_i^k(t+1) = \begin{cases} 1 & rand < T\left(v_i^k(t+1)\right) \\ 0 & rand \geq T\left(v_i^k(t+1)\right) \end{cases} \quad (۱۳)$$

$$x_i^k(t+1) = \begin{cases} \left(x_i^k(t)\right)^{-1} & ,rand < T\left(v_i^k(t+1)\right) \\ x_i^k(t+1) & ,rand \geq T\left(v_i^k(t+1)\right) \end{cases} \quad (۱۴)$$

که $\left(x_i^k(t)\right)^{-1}$ مکمل $x_i^k(t)$ است [31].

(جدول-۲): توابع تبدیل S شکل و V شکل [31]
(Table-2): -S-shaped and V-shaped transfer functions

خانواده توابع تبدیل V شکل		خانواده توابع تبدیل S شکل	
V_1	$T(x) = \left\lvert erf\left(\frac{\sqrt{\pi}}{2}x\right)\right\rvert = \left\lvert \frac{\sqrt{2}}{\pi}\int_0^{\frac{\sqrt{\pi}}{2}x} e^{-t^2}dt \right\rvert$	S_1	$T(x) = \frac{1}{1+e^{-2x}}$
V_2	$T(x) = \lvert tanh(x)\rvert$	S_2	$T(x) = \frac{1}{1+e^{-x}}$
V_3	$T(x) = \left\lvert \frac{x}{\sqrt{1+x^2}}\right\rvert$	S_3	$T(x) = \frac{1}{1+e^{\left(-\frac{x}{2}\right)}}$
V_4	$T(x) = \left\lvert \frac{2}{\pi} arctan\left(\frac{\pi}{2}x\right)\right\rvert$	S_4	$T(x) = \frac{1}{1+e^{\left(-\frac{x}{3}\right)}}$

در این مقاله برای انتخاب ویژگی BPSO چندهدفه (MOBPSO) به کار گرفته شده و بدین منظور تابع هدفی به‌صورت رابطهٔ (۱۵) تعریف شده است:

$$F(x) = \alpha N + \beta Err \quad (۱۵)$$

اسکالرهای α و β، اعداد ثابتی هستند که با سعی و خطا تعیین شده‌اند. بردار متغیر تصمیم، x، بردار ۴۸تایی دودویی است که صفرشدن درایه i ام آن بدین معناست که ویژگی i ام انتخاب نشده و یک‌شدن آن بدین معناست که ویژگی i ام انتخاب شده است. N، تعداد ویژگی‌های انتخاب‌شده (تعداد درایه‌های غیر صفر بردار x) و Err، خطای طبقه‌بندی است. در این بهینه‌سازی علاوه‌بر کمینه‌سازی خطای طبقه‌بندی، انتخاب کمترین تعداد ویژگی نیز در نظر گرفته شده است. بدیهی است با کاهش تعداد ویژگی‌ها، حجم محاسبات کاهش می‌یابد.

۵-۲- طبقه‌بندی

آخرین مرحلهٔ شبیه‌سازی، طبقه‌بندی ویژگی‌های استخراج‌شده در مراحل قبلی است. جهت طبقه‌بندی، دو الگوریتم BPNN و PSO-SVM به کار برده شده است. آنچه که بیشتر در این مرحله حائز اهمیت است، مقایسهٔ روش‌های حذف نوفه بر اساس نتایج پارامترهای به‌دست‌آمده است. جهت ارزیابی و مقایسهٔ عملکرد روش‌های مختلف حذف نوفه، چهار شاخص آماری، استفاده شده است. شاخص‌ها شامل حساسیت (Sens[1])، قطعیت (Spec[2])، ارزش پیش‌بینی مثبت (PPV[3])، دقت (Acc[4]) و معیار F (FM[5]) هستند. در زیر روابط محاسباتی آنها آورده شده است:

$$Sens = \frac{TP}{TP+FN} \times 100\% \quad (۱۶)$$

$$PPV = \frac{TP}{TP+FP} \times 100\% \quad (۱۷)$$

$$Spec = \frac{TN}{TN+FP} \times 100\% \quad (۱۸)$$

$$Acc = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (۱۹)$$

$$FM = 2\frac{PPV \times Senc}{PPV+Senc} \quad (۲۰)$$

در روابط (۱۶) تا (۲۰)، TP ، TN ، FP و FN به‌ترتیب صحیح مثبت[6]، صحیح منفی[7]، غلط مثبت[8] و غلط منفی[9] هستند [32].

۵-۲-۱- ماشین بردار پشتیبان

ماشین بردار پشتیبان (SVM) روشی قوی و گسترده در زمینهٔ حل مسائل طبقه‌بندی نظارت‌شده است. در اصل طبقه‌بند SVM، حاشیهٔ بین دادهٔ آموزشی و مرز تصمیم را بیشینه می‌کنند که می‌تواند به‌عنوان یک مسألهٔ بهینه‌سازی درجهٔ دوم در یک فضای ویژگی، فرمول‌بندی شود. زیرمجموعهٔ نمونه‌هایی که به مرز تصمیم نزدیکترین فاصله را دارند، به‌عنوان بردارهای پشتیبان شناخته

[1] Sensitivity
[2] Specificity
[3] Positive Predictive Value
[4] Accuracy
[5] F-Measure
[6] True Positive
[7] True Negative
[8] False Positive
[9] False Negative

[Downloaded from jsdp.rcisp.ac.ir on 2026-02-04]
[DOI: 10.52547/jsdp.18.2.163]

می‌شوند [33]. عملکرد SVM را می‌توان از طریق دو پارامتر کنترل کرد: پارامتر پنالتی C که مصالحه میان پیچیدگی تابع تصمیم‌گیری و تعداد نمونه‌های آموزشی را که اشتباه طبقه‌بندی شده‌اند، کنترل می‌کند و پارامتر σ که مربوط به پارامتر به کار رفته در توابع کرنل است [34]. همچنین انتخاب تابع کرنل مناسب هم تأثیر به‌سزایی در بهبود عملکرد آن دارد. در این مقاله به‌وسیلهٔ الگوریتم بهینه‌سازی ازدحام ذرات (PSO)، مقدار دو پارامتر C و σ انتخاب شده است. همچنین از تابع کرنل پایه شعاعی به‌عنوان تابع کرنل انتخاب شده است.

۲-۵-۲- شبکه عصبی پس‌انتشار

شبکه عصبی پس‌انتشار (BPNN)، یک حافظهٔ شرکت‌پذیر قوی دارد و پیش‌بینی پس از آموزش را به‌خوبی انجام می‌دهد؛ بنابراین در این‌جا جهت طبقه‌بندی مورد استفاده قرار گرفته است. جهت یادگیری BPNN، الگوریتم پس‌انتشار گشتاور[1] انتخاب شده است. ساختار در نظر گرفته‌شده برای این الگوریتم، به‌صورت یک لایه ورودی، دو لایه مخفی و یک لایه خروجی و توابع لاجستیک در لایهٔ مخفی استفاده شده است. مدل BPNN پس از انجام یک سری مراحل، زمانی‌که به بیشترین تکرار مورد نظر رسید، خاتمه می‌یابد. درواقع، هنگامی‌که مجموعهٔ ویژگی‌ها به‌همراه ماتریس هدف وارد شبکه عصبی پس‌انتشار شدند و سپس الگوریتم بر روی آنها یک سری محاسبات و پردازش انجام داد، خروجی‌ها به‌صورت خودکار، در شش نوع طبقه، قرار می‌گیرند [20].

۳- یافته‌ها

هدف این مقاله، طبقه‌بندی شش نوع آریتمی قلبی براساس هفده سیگنال گرفته‌شده از پایگاه دادهٔ MIT-BIH [27] است. این داده‌ها مربوط به شش نوع آریتمی N، L، R، P، A و V هستند. هفتاد درصد داده‌ها برای آموزش و سی درصد باقی‌مانده برای آزمون در نظر گرفته شده است. داده‌های آموزش و آزمون به‌صورت تصادفی انتخاب می‌شود و کیفیت طبقه‌بندی بسیار وابسته به این انتخاب است. برای رفع این مشکل، تقسیم‌بندی داده‌ها به دو دسته آموزش و آزمون، k بار تکرار شده است تا وابستگی به انتخاب تصادفی از بین برود. در مقاله حاضر، میانگین نتایج برای k برابر پنج گزارش شده است.

[1] Momentum

برای افزایش شانس انتخاب تمامی داده‌ها به‌عنوان داده آموزش و داده آزمون، تقسیم‌بندی داده‌ها به دو دسته آموزش و تست، k بار تکرار و در انتها نیز مقدار میانگین نتایج گزارش شده است. در این‌جا k برابر پنج انتخاب شده است.

در ابتدا برای پیش‌پردازش، نوفه موجود در سیگنال‌ها به‌وسیلهٔ روش ترکیبی EEMD-DWT حذف شده، سپس به‌منظور استخراج ویژگی، تجزیهٔ بستهٔ موجک (WPD)، به کار رفته است. با توجه به حجم بالای اطلاعات، برای انتخاب بهترین ویژگی‌ها از روش MOBPSO، استفاده شده است. در انتها توسط دو روش SVM مبتنی بر PSO و BPNN ویژگی‌های انتخاب‌شده از سیگنال‌های حاوی آریتمی قلبی، دسته‌بندی شده است.

در شکل (۴) مقدار شاخص‌های دقت، حساسیت، قطعیت، ارزش پیش‌بینی مثبت و معیار F به‌ازای شش نوع آریتمی مختلف برای طبقه‌بند BPNN نشان داده شده است. بالاترین مقدار دقت، قطعیت و ارزش پیش‌بینی مثبت مربوط به ردهٔ P به‌ترتیب با مقدار ۹۹/۸۱٪، ۹۹/۶۶٪، ۹۸/۴۶٪، ۹۹/۲۲٪ است. بالاترین مقدار حساسیت و معیار F مربوط به رده N به‌ترتیب با مقدار ۱۰۰٪ و ۹۸/۷۳٪ است. کمترین مقدار دقت، حساسیت و معیار F مربوط به ردهٔ V به‌ترتیب با مقدار ۹۸/۵۲٪، ۹۴/۱۲٪ و ۹۵/۵۲٪، کمترین مقدار قطعیت مربوط به ردهٔ N با مقدار ۹۹/۲۹٪ و کمترین مقدار ارزش پیش‌بینی مثبت مربوط به ردهٔ A با مقدار ۹۶/۳۶٪ است. میانگین مقدار دقت، حساسیت، قطعیت، ارزش پیش‌بینی مثبت و معیار F میان شش کلاس مختلف برای طبقه‌بند BPNN به‌ترتیب ۹۹/۱۲٪، ۹۷/۰۸٪، ۹۹/۳۸٪، ۹۷/۱۲٪ و ۹۷/۱۰٪ است. در شکل (۵) مقدار شاخص‌های حساسیت، قطعیت، ارزش پیش‌بینی مثبت، معیار F و دقت به‌ازای شش نوع آریتمی مختلف برای طبقه‌بند PSO-SVM نشان داده شده است. بالاترین مقدار دقت، حساسیت و معیار F مربوط به ردهٔ P با مقدار ۱۰۰٪ و بالاترین مقدار قطعیت و ارزش پیش‌بینی مثبت مربوط به رده‌های N، R، P، V و A با مقدار ۱۰۰٪ است. کمترین مقدار دقت مربوط به رده‌های N، R، V و A با مقدار ۹۹/۳۱٪ است.

کمترین مقدار حساسیت، قطعیت، ارزش پیش‌بینی مثبت و معیار F مربوط به ردهٔ L به‌ترتیب با مقدار ۸۷/۵۰٪، ۹۹/۱۷٪، ۹۵/۴۵٪ و ۹۱/۳۰ ٪ است. میانگین مقدار دقت، حساسیت، قطعیت، ارزش پیش‌بینی مثبت و معیار F میان شش ردهٔ مختلف برای طبقه‌بند PSO-

[Downloaded from jsdp.rcisp.ac.ir on 2026-02-04]
[DOI: 10.52547/jsdp.18.2.163]

SVM به‌ترتیب ۹۹/۰۷٪، ۹۵/۱۴٪، ۹۹/۸۶٪، ۹۹/۲۴٪ و ۹۷/۱۵٪ است.

به‌منظور نشان‌دادن برتری الگوریتم EEMD نسبت به EMD، یک‌بار نیز حذف نوفه با روش EMD-DWT صورت گرفته است. همچنین برای نشان‌دادن کارایی بلوک انتخاب ویژگی، دسته‌بندی آریتمی‌ها، بدون استفاده از MOBPSO نیز انجام شده است. در جدول (۲)، مقدار شاخص‌های دقت، حساسیت، قطعیت، ارزش پیش‌بینی مثبت و معیار F برای ۸ ترکیب مختلف، آورده شده است که عبارتند از:

۱- حذف نوفه با EMD-DWT، استخراج ویژگی با WPD و طبقه‌بندی با PSO-SVM؛

۲- حذف نوفه با EMD-DWT، استخراج ویژگی با WPD و طبقه‌بندی با BPNN؛

۳- حذف نوفه با EEMD-DWT، استخراج ویژگی با WPD و طبقه‌بندی با PSO-SVM؛

۴- حذف نوفه با EEMD-DWT، استخراج ویژگی با WPD و طبقه‌بندی با BPNN؛

۵- حذف نوفه با EMD-DWT، استخراج ویژگی با WPD، انتخاب ویژگی با MOBPSO و طبقه‌بندی با PSO-SVM؛

۶- حذف نوفه با EMD-DWT، استخراج ویژگی با WPD، انتخاب ویژگی با MOBPSO و طبقه‌بندی با BPNN؛

۷- حذف نوفه با EEMD-DWT، استخراج ویژگی با WPD، انتخاب ویژگی با MOBPSO و طبقه‌بندی با PSO-SVM؛

۸- حذف نوفه با EEMD-DWT، استخراج ویژگی با WPD، انتخاب ویژگی با MOBPSO و طبقه‌بندی با BPNN.

بالاترین مقدار دقت و حساسیت مربوط به حالتی است که از EEMD-DWT برای حذف نوفه، از MOBPSO برای انتخاب ویژگی و از BPNN برای طبقه‌بندی استفاده شده و به‌ترتیب مقدار ۹۹/۱۲٪ و ۹۷/۰۸٪ به‌دست آمده است. بالاترین مقدار قطعیت، ارزش پیش‌بینی مثبت و معیار F مربوط به حالتی است که از EEMD-DWT برای حذف نوفه، از MOBPSO جهت انتخاب ویژگی و PSO-SVM به‌عنوان طبقه‌بند در نظر گرفته شده و به‌ترتیب مقدار ۹۹/۸۶٪، ۹۹/۲۴٪ و ۹۷/۱۵٪ را داشته است. کم‌ترین مقدار دقت، حساسیت و معیار F مربوط به حالتی است که از EMD-DWT برای حذف نوفه و PSO-SVM جهت طبقه‌بندی به کار رفته و به‌ترتیب مقدار آنها ۹۷/۸۷٪، ۸۸/۸۳٪ و ۹۲/۴۱٪ است. کم‌ترین مقدار قطعیت برابر ۹۹/۰۰٪ و مربوط به حالتی است که از EEMD-DWT برای حذف نوفه و از BPNN برای طبقه‌بندی استفاده شده است. کم‌ترین مقدار قطعیت برابر ۹۴/۹۱٪ و مربوط به حالتی است که EMD-DWT جهت حذف نوفه و BPNN جهت طبقه‌بندی در نظر گرفته شده است.

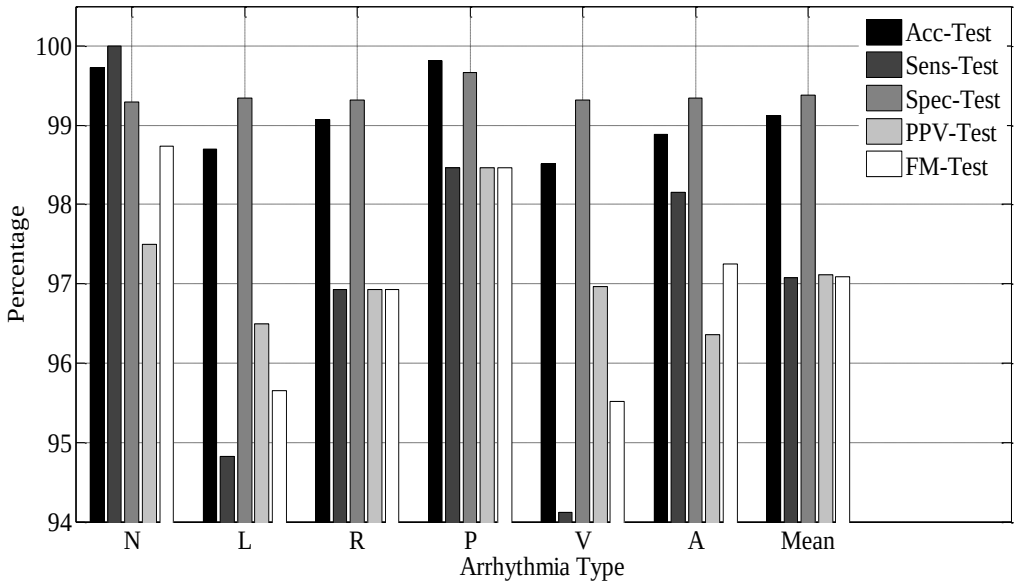

(شکل-۴): شاخص‌های آماری طبقه‌بند BPNN با تکنیک انتخاب ویژگی MOBPSO

(Figure-4): Statistical indices of BPNN classifier with MOBPSO feature selection technique

[Downloaded from jsdp.rcisp.ac.ir on 2026-02-04]

[DOI: 10.52547/jsdp.18.2.163]

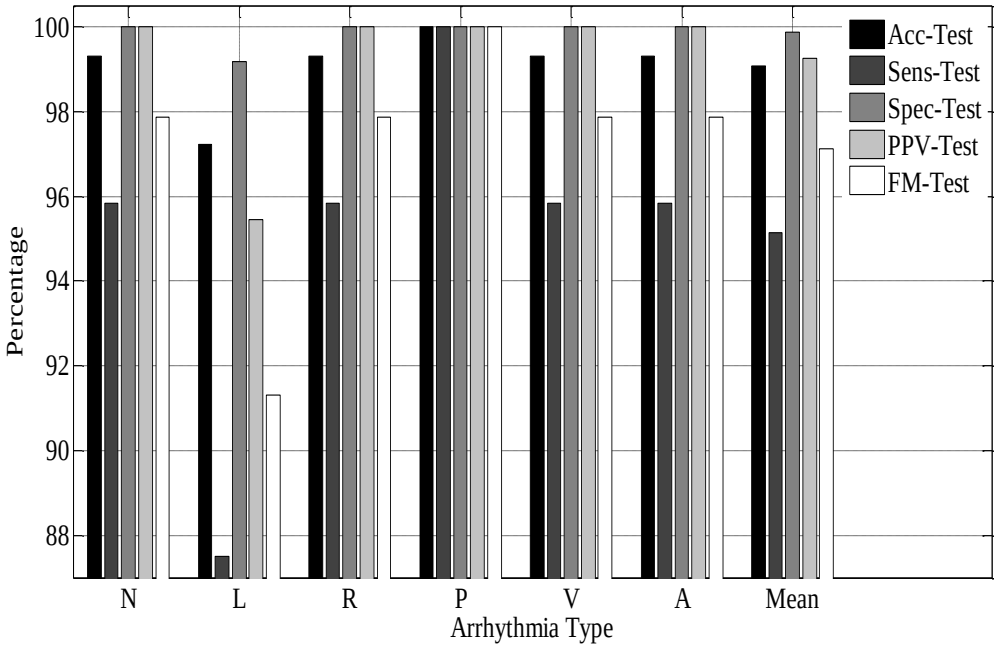

(شکل-۵): شاخص‌های آماری طبقه‌بند PSO-SVM با تکنیک انتخاب ویژگی MOBPSO

(Figure-5): Statistical indices of PSO-SVM classifier with MOBPSO feature selection technique

(جدول-۲): مقدار شاخص‌های Acc، Sens، Spec، PPV و FM بر روی داده‌های آریتمی MIT-BIH

(Table-2): Values for Acc, Sens, Spec, PPV and FM indices on MIT-BIH arrhythmia data

پیش‌پردازش	ویژگی	انتخاب ویژگی	طبقه‌بند	Acc-Test	Sens-Test	Spec-Test	PPV-Test	FM-Test
EMD-DWT	WPD	-	PSO-SVM	۹۷/۸۷	۸۸/۸۳	۹۹/۲۹	۹۶/۳۰	۹۲/۴۱
EMD-DWT	WPD	-	BPNN	۹۷/۹۵	۹۲/۵۲	۹۹/۰۲	۹۴/۹۱	۹۳/۷۰
EEMD-DWT	WPD	-	PSO-SVM	۹۸/۲۱	۹۰/۱۷	۹۹/۸۲	۹۹/۰۶	۹۴/۴۱
EEMD-DWT	WPD	-	BPNN	۹۸/۵۰	۹۰/۰۹	۹۹/۰۰	۹۵/۰۰	۹۲/۴۸
EMD-DWT	WPD	MOPBSO	PSO-SVM	۹۸/۷۱	۹۳/۹۴	۹۹/۴۴	۹۷/۲۷	۹۵/۵۸
EMD-DWT	WPD	MOPBSO	BPNN	۹۸/۹۰	۹۵/۸۳	۹۹/۵۲	۹۷/۶۰	۹۶/۷۱
EEMD-DWT	WPD	MOPBSO	PSO-SVM	۹۹/۰۷	۹۵/۱۴	۹۹/۸۶	۹۹/۲۴	۹۷/۱۵
EEMD-DWT	WPD	MOPBSO	BPNN	۹۹/۱۲	۹۷/۰۸	۹۹/۳۸	۹۷/۱۲	۹۷/۱۰

(جدول-۳): مقایسه مقدار دقت مقاله حاضر با دیگر تحقیقات بر روی داده‌های آریتمی MIT-BIH

(Table-3): Comparison of the accuracy of this article with other studies on MIT-BIH arrhythmia data

روش	پیش‌پردازش	استخراج ویژگی	انتخاب ویژگی	طبقه‌بند	تعداد کلاس	دقت
[35]	-	همبستگی متقابل	-	LS-SVM	۳	٪۹۵/۵۱-۹۶/۱۲
[36]	Spline مکعبی	DWT	-	FLVQ	۴	٪۹۵/۵۰
[22]	-	ریخت‌شناسی	-	SVM	۵	٪۹۵/۲۱
[37]	SWT	HOS و ویژگی‌های زمانی	-	BA-RBF	۵	٪۹۵/۷۹
[26]	فیلتر	CFASE	IG	RF	۵	٪۹۸/۰۸
[20]	-	WPD	GA	BPNN	۶	٪۹۷/۷۸
[21]	فیلتر	ریخت‌شناسی	-	ANFIS	۶	٪۹۸/۴۳
مقاله حاضر	EEMD-DWT	WPD	MOBPSO	BPNN	۶	٪۹۹/۱۲

در جدول (۳)، بیشترین دقت حاصل از دو طبقه‌بند پیشنهادی مقاله حاضر با دقت یادشده در پنج پژوهش دیگر مقایسه شده است. دادهٔ مورد بررسی در تمامی این مقالات، داده MIT-BIH [27] است. تعداد رده‌ها

[Downloaded from jsdp.rcisp.ac.ir on 2026-02-04]

[DOI: 10.52547/jsdp.18.2.163]

نشان‌دهندهٔ انواع آریتمی‌هایی است که در آن مرجع بررسی و طبقه‌بند برای تشخیص آن‌ها طراحی شده است. بدیهی است که با افزایش انواع آریتمی‌ها، طراحی طبقه‌بند دشوارتر است.

در [35] ویژگی‌های مبتنی بر همبستگی متقابل برای استخراج ویژگی و ماشین بردار پشتیبان کمینه مربعات (LS-SVM[1]) برای طبقه‌بندی انتخاب شده است. آنها توانستند با دقت ۹۶/۱۲٪-۹۵/۵۱٪، سه رده آریتمی را دسته‌بندی کنند.

در [36] از Spline مکعبی برای حذف نوفه، از DWT برای استخراج ویژگی و از کمی‌ساز بردار یادگیرنده عصبی فازی (FLVQ[2]) جهت طبقه‌بندی انتخاب شده است که آنها توانستند با دقت ۹۵/۵۰٪، چهار رده آریتمی را دسته‌بندی کنند. در [22] ویژگی‌های ریخت‌شناسی و طبقه‌بند SVM به کار برده شده و پنج ردهٔ آریتمی با دقت ۹۵/۲۱٪ دسته‌بندی شده است.

در [37] از تبدیل موجک ایستا (SWT[3])، ترکیب آمارگان مراتب بالا (HOS[4]) با ویژگی‌های زمانی و تابع پایه شعاعی مبتنی بر الگوریتم زنبورها (BA-RBF[5]) به‌ترتیب برای حذف نوفه، استخراج ویژگی و طبقه‌بندی انتخاب شده‌اند و مقدار دقت برای پنج ردهٔ آریتمی ۹۵/۷۹٪ گزارش شده است. در [26] از فیلترکردن، ترکیب تحلیل فرکانس و آنتروپی شانون (CFASE[6])، بهره اطلاعاتی (IG[7]) و جنگل تصادفی به‌ترتیب برای حذف نوفه، استخراج ویژگی، انتخاب ویژگی و طبقه‌بندی استفاده شده و مقدار دقت برای پنج ردهٔ آریتمی ۹۸/۰۸ ٪ گزارش شده است. در [20] از WPD برای استخراج ویژگی، الگوریتم ژنتیک (GA[8]) برای انتخاب ویژگی و BPNN برای طبقه‌بندی شش ردهٔ آریتمی در نظر گرفته شده که مقدار دقت ۹۷/۷۸٪ به‌دست آمده است.

در [21] از ویژگی‌های ریخت‌شناسی برای استخراج ویژگی و ANFIS برای طبقه‌بندی شش ردهٔ آریتمی در نظر گرفته شده که مقدار دقت ۹۸/۴۳٪ به‌دست آمده است.

مقدار دقت برای هر هشت حالت مختلف مقاله حاضر (جدول ۲)، از مقدار دقت گزارش‌شده به‌وسیلهٔ پنج پژوهش دیگر (جدول ۳) بیشتر بوده است. بالاترین مقدار دقت مربوط به زمانی است که EEMD-DWT، WPD، MOBPSO و BPNN به‌ترتیب برای حذف نوفه، استخراج ویژگی، انتخاب ویژگی و طبقه‌بندی به کار رفته و مقدار دقت ۹۹/۱۲٪ است.

۴- بحث و نتیجه‌گیری

هدف از مقاله حاضر، طبقه‌بندی آریتمی‌های قلبی است که بدین منظور از هفده عدد سیگنال ECG گرفته‌شده از پایگاه داده MIT-BIH، استفاده شده است. با توجه به نوفه‌ای‌بودن داده‌ها، ترکیب EEMD و DWT (EEMD-DWT) برای حذف نوفه این سیگنال غیرایستا به‌کار گرفته شده است. جهت نشان‌دادن برتری روش EEMD، یک‌بار نیز ترکیب EMD-DWT بررسی شده است. در ادامه، ویژگی‌های آماری مربوط به ضرایب تجزیهٔ بستهٔ موجک یعنی مقدار بیشینه، انحراف معیار و مقدار تکین از سیگنال استخراج شده است. جهت بالارفتن سرعت پردازش به‌وسیلهٔ MOBPSO، بهترین ویژگی‌ها انتخاب و با رده‌بند BPNN و PSO-SVM داده‌های شش ردهٔ مختلف دسته‌بندی شده است. گفتنی است یک‌بار نیز طبقه‌بندی برای تمام ویژگی‌ها انجام شده است تا کارایی MOBPSO ارزیابی شود.

نتایج نشان داده است که بالاترین مقدار دقت مربوط به آریتمی رده نوع P است. مقدار دقت در حالتی‌که حذف نوفه با روش EEMD-DWT انجام شود، نسبت به حالت EMD-DWT بالاترین مقدار را داشته است. همچنین مقدار دقت در حالتی‌که بهترین ویژگی‌ها با روش MOBPSO انتخاب می‌شوند، نسبت به زمانی‌که تمام ویژگی‌ها وارد طبقه‌بند می‌شوند، بالاترین مقدار را داشته است. رده‌بند BPNN نیز مقدار دقت بیشتری را در مقایسه با رده‌بند PSO-SVM نشان داده است. مقایسه نتایج به‌دست‌آمده از این پژوهش با دیگر پژوهش‌های نشان می‌دهد که هر یک از روش‌های مربوط به قسمت پیش‌پردازش، انتخاب ویژگی و یا رده‌بندی می‌تواند آریتمی‌های قلبی را با دقت بالاتری از یکدیگر تفکیک کرد.

۵- مراجع 5- References

[۱]. گایتون آ، هال ج ا، ۱۳۸۹، "فیزیولوژی پزشکی"، ترجمه شادان ف، تهران، انتشارات چهر، جلد اول.

[1] A. Guyton, H. Hall, "Medical Physiology", Translated by F. Shadan, Tehran, Chehr Publication, Vol. I, 2010.

[1] Least Square Support Vector Machine
[2] Fuzzy Neuro Learning Vector Quantization
[3] Stationary Wavelet Transform
[4] Higher Order Statistics
[5] Bees Algorithm-Radial Basis Function
[6] Combined Frequency Analysis and Shannon entropy
[7] Information Gain
[8] Genetic Algorithm

[Downloaded from jsdp.rcisp.ac.ir on 2026-02-04]
[DOI: 10.52547/jsdp.18.2.163]

[2].Md. A. Kabir and C. Shahnaz, "Denoising of ECG Signals Based on Noise Reduction Algorithms in EMD and Wavelet Domains," Biomedical Signal Processing and Control, vol. 7, no. 5, pp. 481– 489, 2012.

[3].N. Li and P. Li, "An Improved Algorithm Based on EMD-Wavelet for ECG Signal De-noising," In: International Joint Conference on Computational Sciences and Optimization, Sanya, pp. 825–827, 2009.

[4].K. M. Chang, "Arrhythmia ECG Noise Reduction by Ensemble Empirical Mode Decomposition," Sensors, vol. 10, no. 6, pp. 6063-6080, 2010.

[5].S. Poungponsri and X. H. Yu, "An Adaptive Filtering Approach for Electrocardiogram (ECG) Signal Noise Reduction Using Neural Networks," Neurocomputing, vol. 117, pp. 206–213, 2013.

[6].H. Y. Lin, S. Y. Liang, Y. L. Ho, Y. H. Lin and H. P. Ma, "Discrete-Wavelet-Transform-Based Noise Removal and Feature Extraction for ECG Signals," IRBM, vol. 35, no. 6, pp. 351-361, 2014.

[7].V. Joshi, A. R. Verma and Y. Singh, "De-noising of ECG Signal Using Adaptive Filter Based on MPSO," Procedia Computer Science, vol. 57, pp. 395-402, 2015.

[8].S. Karpagachelvi, M. Arthanari and M. Sivakumar, "ECG Feature Extraction Techniques - A Survey Approach," International Journal of Computer Science and Information Security, vol. 8, no. 1, 2010, arXiv: 1005.0957.

[9].S. Coumo, G. De. Pietro, R. Farina, A. Galletti and G. Sannino, "A Revised Scheme for Real Time ECG Signal Denoising Based on Recursive Filtering", Biomedical Signal Processing and Control, vol. 27, pp. 134-144, 2016.

[10]. M. Korurek and A. Nizam, "Clustering MIT–BIH arrhythmias with ant colony optimization using time domain and PCA compressed wavelet coefficients," Digital Signal Processing, vol. 20, no. 4, pp. 1050-1060, 2010.

[11]. N. Acir, "Classification of ECG beats by using a fast least square support vector machines with a dynamic programming feature selection algorithm," Neural Computing & Applications, vol. 14, no. 4, pp. 299-309, 2005.

[12]. P. de Chazal, M. O'Dwyer and R. B. Reilly, "Automatic classification of heartbeats using ECG morphology and heartbeat interval features", IEEE Transactions on Biomedical Engineering, vol. 51, no. 7, pp. 1196-1206, 2004.

[13]. M. Lagerholm, C. Peterson, G. Braccini, L. Edenbrandt and L. Sornmo, "Clustering ECG complexes using hermite functions and self-organizing maps," IEEE Transactions on Biomedical Engineering, vol. 47, no. 7, pp. 838–848, 2000.

[14]. L. Senhadji, J. J. Bellanger, G. Carrault and G. Passariello, "Comparing wavelet transforms for recognizing cardiac patterns," IEEE Engineering in Medicine and Biology Magazine, vol. 14, no. 2, pp. 167–173, 1995.

[15]. R. Rodriguez, A. Mexicano, J. Bila, S. Cervantes and R. Ponce, "Feature Extraction of Electrocardiogram Signals by Applying Adaptive Threshold and Principal Component Analysis," Journal of Applied Research and Technology, vol. 13, no. 2, pp. 261-269, 2015.

[16]. A. Ghaheri, S. Shoar, M. Naderan and S. S. Hoseini, "The Applications of Genetic Algorithms in Medicine," Oman Medical Journal, vol. 30, no. 6, pp. 406–416, 2015.

[17]. Y. Kutlua and D. Kuntalp, "Feature extraction for ECG heartbeats using higher order statistics of WPD coefficients," Computer Methods and Programs in Biomedicine, vol. 105, no. 3, pp. 257-267, 2012.

[18]. P. Kora and K. S. R. krishna, "Hybrid Firefly and Particle Swarm Optimization algorithm for the detection of Bundle Branch Block," International Journal of the Cardiovascular Academy, vol. 2, no. 1, pp. 44-48, 2016.

[19]. J. S. Wang, C. W. Lin and Y. T. C. Yang, "A k-nearest-neighbor classifier with heart rate variability feature-based transformation algorithm for driving stress recognition," Neurocomputing, vol. 116, pp.136–143, 2013.

[20]. H. Li, D. Yuan, X. Ma, D. Cui and L. Cao, "Genetic Algorithm for the Optimization of Features and Neural Networks in ECG Signals Classification," Scientific Reports, vol. 7, pp. 41011, 2017, doi: 10.1038/srep41011.

[21]. P. R. Bokde, "An ECG Beat Classification Using Adaptive Neuro-Fuzzy Inference System," International Research Journal of Advanced Engineering and Science, vol. 2. No. 2, pp. 354-358, 2017.

[22]. P. Bhardwaj, R. R. Choudhary and R. Dayama, "Analysis and Classification of Cardiac Arrhythmia Using ECG Signals," International Journal of Computer Applications, vol. 38, no. 1, pp. 37-40, 2012.

[۲۳]. رهبری پور، م. و محمدزاده اصل، ب. ۱۳۹۷. تشخیص آریتمی انقباضات زودرس بطنی در سیگنال الکتریکی قلب با استفاده ازترکیب طبقه بندها. پردازش علایم و داده ها, ۱۵(۱), ۵۵-۷۰.

[Downloaded from jsdp.rcisp.ac.ir on 2026-02-04]

[DOI: 10.52547/jsdp.18.2.163]

[23]. M. Rahbaripour and B. Mohammadzadeh Asl. “Premature Ventricular Contraction Arrhythmia Detection in ECG Signals via Combined Classifiers”. JSDP. 2018; 15 (1) :55-70

[24]. J. Rodriguez, A. Goni and A. Illarramendi, “Real-Time Classification of ECGs on a PDA,” IEEE Transactions on Information Technology in Biomedicine, vol. 9, no. 1m pp. 23-34, 2005.

[25]. S. Kiranyaz, T. Ince and M. Gabbouj, “Real-Time Patient-Specific ECG Classification by 1D Convolutional Neural Networks,” IEEE Transactions on Biomedical Engineering, vol. 63, no. 3, pp. 664-675, 2016.

[26]. Y. Zhang, Y. Zhang, B. Lo, W. Xu, “Wearable ECG signal processing for automated cardiac arrhythmia classification using CFASE-based feature selection,” John Wiley & Sons, Ltd, 2019, DOI: 10.1111/exsy.12432.

[27]. G. B. Moody and R. G. Mark, “The Impact of the MIT-BIH Arrhythmia Database,” IEEE Engineering in Medicine and Biology Society, vol. 20, no. 3, pp. 45–50, 2001.

[28]. P. Nguyen and J. M. Kim, “Adaptive ECG Denoising Using Genetic Algorithm-Based Thresholding and Ensemble Emprical Mode Decomposition,” Information Sciences, vol. 373, pp. 499-511, 2016.

[29]. S. G. Chang, B. Yu and M. Vetterli, “Adaptive wavelet thresholding for image denoising and compression,” IEEE Transactions on Image Processing, vol. 9, no. 9, pp. 1532-1546, 2000.

[30]. Y. Kutlu and D. Kuntalp, “Feature Extraction for ECG Heartbeats Using Higher Order Statistics of WPD Coefficients,” Computer Methods and Programs in Biomedicine, vol. 105, no. 3, pp. 257-267, 2012.

[31]. S. Mirjalili and A. Lewis, “S-shaped versus V-shaped transfer functions for binary Particle Swarm Optimization,” Swarm and Evolutionary Computation, vol. 9, pp. 1-14, 2013.

[32]. R. Parikh, A. Mathai, S. Parikh, G. C. Sekhar and R. Thomas, “Understanding and using sensitivity, specificity and predictive values,” Indian Journal of Ophthalmology, vol. 56, no. 1, pp. 45-50, 2008.

[33]. S. S. Mehta and N. S. Lingayat, “SVM-Based Algorithm for Recognition of QRS Complexes in Electrocardiogram,” IRBM, vol. 29, pp. 310-317, 2008.

[34]. J. Saeedi, S. M. Ahadi and K. Faez, “Robust voice activity detection directed by noise classification. Signal,” Image and Video Processing, vol. 9, no. 3, pp. 561–572, 2013.

[35]. S. Dutta, A. Chatterjee and S. Munshi, “Correlation technique and least square support vector machine combine for frequency domain based ECG beat classification,” Medical Engineering & Physics, vol. 32, no. 10, pp. 1161–1169, 2010.

[36]. W. Jatmiko, W. P. Nulad, I. E. Matul, I. M. A. Setiawan and P. Mursanto, “Heart Beat Classification Using Wavelet Feature Based on Neural Network,” WSEAS Transactions on Systems, vol. 10, no. 1, pp. 17-26, 2011.

[37]. A. Ebahimzadeh, B. Shakiba and A. Khazaee, “Detection of electrocardiogram signals using an efficient method,” Applied Soft Computing, vol. 22, pp. 108–117, 2014.

مهسا واقفی مدرک کارشناسی را از دانشگاه شریعتی در رشته مهندسی برق-الکترنیک، کارشناسی ارشد و دکترا را در رشته مهندسی پزشکی-بیوالکترنیک به‌ترتیب از دانشگاه شاهد و دانشگاه آزاد اسلامی واحد علوم تحقیقات تهران دریافت کرد. ایشان در حال حاضر استادیار گروه مهندسی برق در دانشگاه آزاد اسلامی واحد شیراز است. زمینه‌های پژوهشی اصلی مورد علاقه نامبرده پردازش سیگنال، شبکه عصبی و بازشناسی آماری الگو است.

نشانی رایانامه ایشان عبارت است از:

vaghefi@iaushiraz.ac.ir

فاطمه جمشیدی مدرک کارشناسی را از دانشگاه علوم پزشکی جندی شاپور اهواز، در رشته مهندسی پزشکی-بالینی، کارشناسی ارشد و دکترا را در رشته مهندسی برق-کنترل به‌ترتیب از دانشگاه شیراز و تربیت مدرس دریافت کرد. ایشان در حال حاضر، استادیار گروه مهندسی برق دانشگاه فسا است. زمینه‌های پژوهشی اصلی مورد علاقه نامبرده الگوریتم‌های هوشمند، کنترل مقاوم، کنترل سیستم‌های قدرت، رباتیک، جبر خطی، سامانه‌های فازی است.

نشانی رایانامه ایشان عبارت است از:

Jamshidi@fasau.ac.ir

[Downloaded from jsdp.rcisp.ac.ir on 2026-02-04]

[DOI: 10.52547/jsdp.18.2.163]