

## ارزیابی عملکرد طبقه‌بندهای SVM و FFNN در طبقه‌بندی آریتمی‌های قلبی با ویژگی‌های تبدیل موجک

زهرا رستمی<sup>۱</sup>، روزبه رجبی<sup>۲</sup>

<sup>۱</sup>دانش‌آموخته‌ی کارشناسی مهندسی برق مخابرات، دانشگاه صنعتی قم

<sup>۲</sup>استادیار دانشکده مهندسی برق و کامپیوتر، دانشگاه صنعتی قم، rajabi@qut.ac.ir

### چکیده

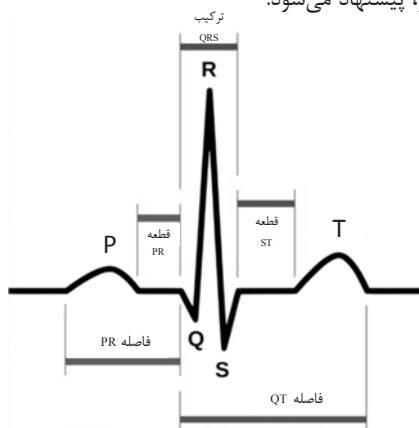
سیگنال الکتروکاردیوگرام، نشان‌دهنده‌ی فعالیت الکتریکی قلب و یکی از مهمترین کاربردهای آن تشخیص آریتمی‌های قلبی است. اما تحلیل یک ثبت طولانی از این سیگنال، با دشواری‌هایی رو به رو است. بنابراین نیاز به استفاده از روش‌های تشخیص خودکار، روز به روز بیشتر احساس می‌شود. در این مقاله الگوریتمی با استفاده از ویژگی‌های استخراج شده از تبدیل موجک و طبقه‌بند SVM پیشنهاد شده است. برای این منظور ابتدا نویزهای سیگنال، توسط فیلتر دیجیتال و تبدیل موجک حذف شده؛ سپس با الگوریتم Pan\_Tompkins موج‌های R، استخراج شده‌اند. در ادامه ویژگی‌های هر ضربان قلب با تبدیل موجک گسسته استخراج شده و ابعاد فضای ویژگی‌ها با تبدیل PCA کاهش یافته است. سپس طبقه‌بندی با روش SVM و کرنل‌های مختلف آن انجام شده است. از داده‌های پایگاه MIT-BIH arrhythmia و نرم‌افزار MATLAB جهت ارزیابی کارایی روش پیشنهادی در مقایسه با روش متداول Feed-Forward Neural Network (FFNN) استفاده شده است. پنج کلاس شامل ضربان‌های نرمال (N) و آریتمی‌های انسداد دسته شاخه چپ (LBBB)، انسداد دسته شاخه راست (RBBB)، انقباض زودرس دهلیزی (APB) و ضربان paced (PB)، با صحت ۹۵/۶۸ درصد با SVM در بهترین حالت و صحت ۹۰/۳۰ درصد با FFNN طبقه‌بندی شده است. نتایج نشان‌دهنده تشخیص موثرتر آریتمی‌های قلبی توسط روش پیشنهادی است.

### کلیدواژه

الکتروکاردیوگرام، آریتمی، تبدیل موجک گسسته، تبدیل PCA، روش SVM

### مقدمه

روبه‌رو هستند. برای حل این مسئله، استفاده از روش‌های خودکار، پیشنهاد می‌شود.



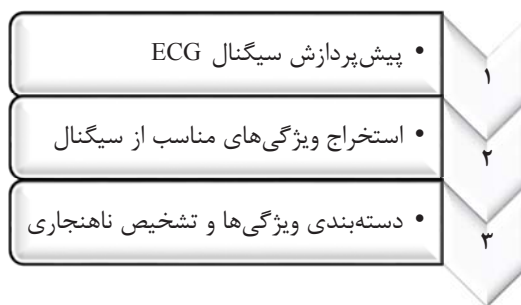
شکل ۱. یک ضربان عادی سیگنال ECG

اغلب روش‌هایی که در این زمینه ارائه شده‌اند شامل سه مرحله می‌باشند. این مراحل در شکل ۲ نشان داده شده است.

بیماری‌های قلبی دسته‌ای از بیماری‌ها هستند که تشخیص سریع آن‌ها اهمیت ویژه‌ای دارد، زیرا با تشخیص سریع و درمان به موقع، می‌توان از مرگ ناگهانی بیمار جلوگیری کرد. پزشکان برای تشخیص وضعیت سلامت یا بیمار بودن قلب، از سیگنال الکتروکاردیوگرام (ECG) بهره می‌گیرند.

یک ضربان عادی این سیگنال در شکل ۱ نشان داده شده است؛ که شامل موج P ترکیب QRS موج T و تعدادی قطعه و فاصله است. هر موج آن، با فعالیت یک ماهیچه قلب، تولید شده و تغییر هریک، از حالت عادی، آریتمی یا ناهنجاری نامیده می‌شود. متخصصان برای تحلیل یک ثبت ECG طولانی، با مشکلاتی از قبیل وقت‌گیر بودن تحلیل سیگنال، از دست دادن اطلاعات بسیار جزئی و احتمال رخ دادن خطا در تشخیص،

<sup>۱</sup> Electrocardiogram



شکل ۲. مراحل انجام کار در روش های خودکار تشخیص آریتمی قلبی از

روی سیگنال ECG

هنگام ثبت سیگنال، نویز، از منابع گوناگون وارد سیگنال می شود. بنابراین ابتدا یک پردازش اولیه برای حذف این نویزها انجام می گیرد. برای این کار از ابزارهایی مانند فیلترهای دیجیتال [۱]، فیلترهای تطبیقی [۲]، تبدیل موجک [۳] و ... استفاده شده است. فیلترها به مقدار پارامترهای طراحی حساس هستند. از طرفی به دلیل غیر ایستا بودن سیگنال ECG تبدیل موجک روش مناسب تری است.

پس از حذف نویزها، با روش های مختلف، ویژگی های متمایز کننده هر دسته از آریتمی ها از سیگنال استخراج می شود. در بعضی از روش ها ابتدا محل پیک های R استخراج می شود. استخراج پیک های R با هدف های گوناگون انجام می شود. برای مثال یکی از این اهداف، محاسبه نرخ ضربان قلب است. استخراج محل پیک های R با روش های متنوعی مانند استفاده از تبدیل هیلبرت [۴]، الگوریتم Pan\_Tompkins [۵] و تبدیل موجک [۶] انجام شده است. در میان این روش ها تبدیل موجک از سرعت بالایی برخوردار است.

سپس ویژگی هایی مانند: پارامترهای سیگنال (دامنه موج ها و اندازه قطعه ها و فاصله ها) [۷]، اطلاعات آماری سیگنال [۸]، توابع هرمیت [۹]، ویژگی های فرکانسی استخراج شده از طیف سیگنال [۱۰] و ضرایب حاصل از تبدیل موجک [۱۱]، از سیگنال استخراج شده است. نتایج نشان داده است، روش هایی که ویژگی ها را از سیگنال تبدیل یافته استخراج می کنند سرعت و صحت قابل قبولی در میان روش های دیگر دارند.

گاهی ابعاد فضای ویژگی های استخراج شده زیاد است. این مسئله باعث کاهش دقت طبقه بندی می شود. برای حل آن، از روش هایی مانند تحلیل مؤلفه های اصلی (PCA) [۱۲] و تحلیل مؤلفه های مستقل (ICA) [۱۱] و ... استفاده شده است. در بعضی روش ها از الگوریتم های انتخاب بهترین ویژگی ها مانند الگوریتم جستجوی ترتیبی شناور رو به جلو (SFFS) [۱۳] برای افزایش دقت طبقه بندی استفاده می کنند.

در مرحله آخر برای دسته بندی ویژگی ها و تشخیص نوع آریتمی هر ضربان قلب، از طبقه بندی های مختلف، با انواع الگوریتم های یادگیری، استفاده شده است.

در طبقه بندی نظارت شده از شبکه های عصبی مصنوعی [۱۴] و ماشین بردار پشتیبان (SVM) [۱۵]، استفاده شده است.

در طبقه بندی نیمه نظارتی از SVM [۱۶] و شبکه عصبی عمیق (DNN) (در این روش ویژگی ها به صورت خودکار استخراج می شوند) [۱۷] با تکنیک های یادگیری فعال، استفاده شده است.

در بعضی مقالات برای افزایش دقت طبقه بندی از الگوریتم های بهینه سازی مانند الگوریتم جستجوی فاخته برای آموزش طبقه بندی استفاده شده است [۱۸].

اگرچه پژوهش های بسیاری توسط محققان در این زمینه صورت گرفته است؛ اما به دلیل اهمیت موضوع، همچنان تلاش برای یافتن روش هایی که میزان خطای تشخیص را به حداقل برساند، ضروری است.

در این مقاله، ساختار ترکیبی از ویژگی های تبدیل موجک و طبقه بندی ماشین بردار پشتیبان (SVM) با کرنل های مختلف پیشنهاد شده است. برای مقایسه و ارزیابی نتایج، از طبقه بندی شبکه عصبی استفاده شده است.

در ادامه ساختار مقاله به این صورت است که در بخش دوم توضیحات راجع به پیش پردازش سیگنال، در بخش سوم کارهای انجام شده در مرحله استخراج ویژگی، در بخش چهارم طبقه بندی آریتمی ها و در بخش آخر، نتایج ارائه شده است.

### پیش پردازش سیگنال

مهمترین نویزهایی که به سیگنال اضافه می شود عبارتند از: انحراف از خط زمینه و تداخل خطوط برق شهر.

#### حذف نویز انحراف از خط زمینه

این مورد، یک سیگنال فرکانس پایین است و به علت های مختلف مانند تنفس، حرکات بدن و ... ایجاد می شود. کوچکترین مؤلفه فرکانسی سیگنال ECG در بدترین حالت ۰/۶۷ هرتز است [۱۹]. بنابراین در این مقاله برای حذف آن از یک فیلتر با پاسخ ضربه نامحدود (IIR) بالاگذر (چپیشف نوع II) با فرکانس قطع کوچکتر از ۰/۶۷ هرتز، استفاده شده است. به دلیل غیرخطی بودن پاسخ فاز این نوع فیلتر، آن را به روش پیشرو - پسرو به سیگنال، اعمال کرده یعنی ابتدا سیگنال، فیلتر شده، خروجی حاصل، در زمان، معکوس شده و دوباره فیلتر می شود سپس سیگنال حاصل دوباره در زمان معکوس می شود؛ با این روش پاسخ فاز صفر می شود.

### حذف تداخل خطوط برق شهر

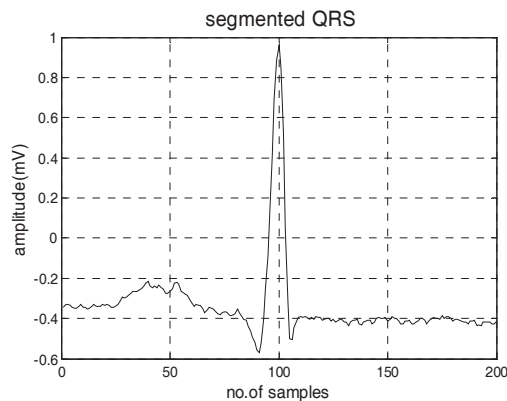
این روش، از فیلترینگ خطی، تبدیل غیرخطی و آستانه‌گذاری تطبیقی برای استخراج موج‌های R استفاده می‌کند. مراحل انجام این الگوریتم در شکل ۴ نشان داده شده است [۵].



شکل ۴. مراحل روش Pan\_Tompkins در یافتن موج‌های R سیگنال ECG

### جدا سازی ضربان‌های سیگنال

با استفاده از محل موج‌های R، که در مرحله قبل استخراج شده‌اند، سیگنال، به اندازه ۲۰۰ نمونه به عنوان یک ضربان، قطعه‌بندی شده است. تعداد ۹۹ نمونه قبل از موج R، ۱۰۰ نمونه بعد از موج R به همراه موج R یک ضربان را تشکیل می‌دهند. نمونه‌ای از یک ضربان جدا شده در شکل ۵ نشان داده شده است.



شکل ۵. نمایش یک ضربان جدا شده از سیگنال ECG

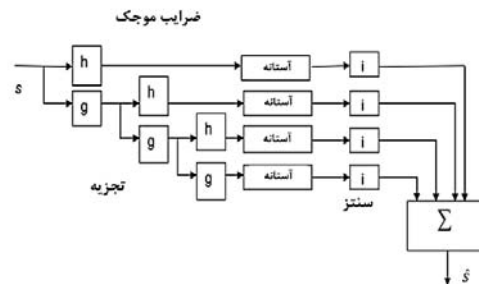
### تبدیل موجک گسسته

هر ضربان، توسط تبدیل موجک گسسته، با استفاده از موجک "mayer" به ۴ سطح تجزیه شده است. تعداد سطوح تجزیه در این مرحله، با توجه به طیف فرکانسی سیگنال انتخاب می‌گردد. در تجزیه سیگنال توسط تبدیل موجک گسسته، فرکانس ضرایب سیگنال در هر سطح، نصف سطح قبل است؛ سیگنال‌های موجود در پایگاه داده MIT-BIH arrhythmia با فرکانس ۳۶۰ هرتز نمونه برداری شده‌اند؛ در نتیجه پهنای باند سیگنال ۱۸۰ هرتز است. بنابراین ضرایب سیگنال در سطح چهارم دارای محدوده فرکانسی ۰ تا ۱۱/۲۵ هرتز برای ضرایب تقریب و ۲۲/۵ - ۱۱/۲۵ هرتز برای ضرایب جزئیات است. نشان داده شده است که چگالی طیف توان طبقه‌های مختلف آریتمی در این محدوده فرکانسی، دارای اطلاعات متمایز است

این نویز، شامل یک تک فرکانس ۵۰ یا ۶۰ هرتز است که از خطوط برق وارد سیگنال می‌شود؛ و در مقایسه با محدوده فرکانسی سیگنال ECG نویزی فرکانس بالا محسوب می‌شود.

برای حذف آن، از تبدیل موجک گسسته استفاده شده است. این روش، سیگنال اصلی، توسط یک موجک مناسب، به تعداد سطوح معین تجزیه می‌شود. در هر سطح یک ضریب تقریب و یک ضریب جزئیات وجود دارد. با آستانه‌گذاری روی ضرایب جزئیات هر سطح، مؤلفه‌های ناخواسته، از سیگنال حذف می‌شود. در نهایت با استفاده از ضرایب اصلاح شده، سیگنال بازسازی می‌گردد.

یکی از معیارهای انتخاب موجک مناسب، شباهت آن به سیگنال اصلی است. تعداد سطوح تجزیه و روش آستانه با روش آزمون و خطا تعیین می‌شوند. مراحل انجام این روش در شکل ۳ نشان داده شده است.



شکل ۳. نمایش روش حذف نویزهای فرکانس بالا توسط تبدیل موجک گسسته [۳].

سیگنال حاصل از مرحله قبل توسط موجک "sym9" با روش انتخاب آستانه "MinMax" (یک روش آستانه‌گذاری خودکار در MATLAB) و در ۵ مرحله پردازش شد.

### استخراج ویژگی‌ها

در این مرحله ابتدا برای قطعه‌بندی سیگنال به اندازه یک ضربان، محل موج‌های R از سیگنال استخراج شده؛ زیرا موج R بلندترین موج سیگنال است و استخراج آن نسبت به موج‌های دیگر، آسان‌تر است. سپس ویژگی‌های هر قطعه استخراج شده است.

### استخراج موج R

روش Pan\_Tompkins به دلیل پیاده‌سازی آسان و دقت بالا در یافتن موج‌های R، برای انجام این مرحله، انتخاب شده است.

<sup>†</sup> Approximation coefficients  
<sup>‡</sup> Detail coefficients

تعداد ۶ مؤلفه اصلی برای هر ماتریس X، انتخاب شده است. بنابراین ۱۲ مؤلفه با هم برای هر ضربان، بردار ویژگی و ورودی سیستم طبقه بندی را تشکیل می دهند.

### طبقه بندی

پس از انجام مراحل فوق، ماتریسی که هر سطر آن شامل ویژگی های یک ضربان است بدست می آید.

برای طبقه بندی ویژگی ها و تشخیص نوع آریتمی هر ضربان از طبقه بندی ماشین بردار پشتیبان (SVM) استفاده شده است و برای مقایسه و ارزیابی نتایج از طبقه بندی شبکه عصبی پیشخور<sup>۴</sup> (FFNN) استفاده شده است.

در هر دو مورد، طبقه بندی به صورت نظارت شده است. یعنی طبقه بندی، ابتدا باید توسط داده های برچسب خورده ( داده های آموزشی) آموزش داده شود.

برای این منظور، با استفاده از سیگنال های موجود در پایگاه داده، یک مجموعه داده آموزشی و یک مجموعه داده آزمایشی تهیه شده است. به کمک فایل تفسیر<sup>۵</sup> هر سیگنال، برچسب نوع آریتمی هر ضربان نیز فراهم می گردد.

فایل تفسیر هر سیگنال، که در پایگاه داده موجود است، شامل اطلاعاتی مانند محل وقوع هر موج R و نیز نوع آریتمی هر ضربان است.

ابتدا به کمک داده های آموزشی، طبقه بندی آموزش داده شده و سپس عملکرد آن، توسط داده های آزمایشی ارزیابی شده است.

### طبقه بندی به روش SVM


این طبقه بندی برای جدا کردن دو مجموعه، به جستجوی یک فرافصحه بهینه می پردازد به گونه ای که فاصله نزدیکترین داده ها به صفحه، بیشترین مقدار ممکن شود.

اگر داده ها به صورتی پراکنده شده باشند که جداسازی خطی ممکن نباشد، SVM داده ها را به یک فضا با ابعاد بالاتر می نگارد که جداسازی خطی توسط یک فرافصحه ممکن گردد.

به دلیل مشکلات کار در ابعاد بالا، از یک تابع هسته<sup>۶</sup> استفاده می شود، بنابراین نیازی به نگاه داشتن داده به ابعاد بالا نیست. رایج ترین هسته ها، تابع پایه شعاعی<sup>۷</sup> (RBF)، چند جمله ای<sup>۸</sup> و خطی<sup>۹</sup> هستند.

[۱۱]. بنابراین از ضرایب این سطح برای ایجاد بردار ویژگی استفاده شده است.

روش استخراج ویژگی ها در شکل ۶ خلاصه شده است. پس از بازسازی ضرایب سطح چهارم، تعداد ۲۰۰ نمونه به ازای هر ضریب بدست می آید، سپس این ۲۰۰ نمونه توسط تبدیل PCA به ۶ مؤلفه کاهش می یابد.



شکل ۶. بلوک دیاگرام روش استخراج ویژگی (CA: ضرایب تقریب، CD: ضرایب جزئیات)

### تحلیل مؤلفه اصلی (PCA)

به دلیل زیاد بودن ابعاد فضای ویژگی (تعداد ۴۰۰ ویژگی به ازای هر ضربان)، از تحلیل مؤلفه اصلی (PCA) برای کاهش ابعاد استفاده شده است. این کار باعث بهبود صحت طبقه بندی می گردد.

در این روش محورهای مختصات جدیدی برای داده ها تعریف می شود به گونه ای که اولین محور در جهتی که واریانس داده ها بیشینه است قرار می گیرد. دومین محور نیز عمود بر محور اول و در جهت واریانس بیشینه است. به همین ترتیب محورهای دیگر نیز تعریف می شوند.

ابتدا یک ماتریس X توسط ضرایب بازسازی شده جزئیات سطح چهارم و یک ماتریس X دیگر توسط ضرایب بازسازی شده تقریب سطح چهارم، هر یک با ابعاد  $N \times 200$  ساخته می شود. N تعداد ضربان ها از همه کلاس ها است. سپس میانگین هر ماتریس حساب شده و از آن کم می شود. اگر فرض کنیم Y ماتریس کواریانس X است و A ماتریس بردارهای ویژه و B ماتریس مقادیر ویژه محاسبه شده از ماتریس کواریانس Y باشد و هر عضو A را با  $\phi$  و هر عضو B را با  $\lambda$  نمایش دهیم آنگاه ماتریس مؤلفه های اصلی P شامل بردارهای ویژه متناظر با m مقدار ویژه بزرگتر، می باشد. m تعداد مؤلفه های اصلی است.

$$\lambda_1 > \lambda_2 > \dots > \lambda_m > \dots > \lambda_n \quad (1)$$

$$P = [\phi_1, \phi_2, \dots, \phi_m] \quad (2)$$

در نهایت با ضرب ماتریس مؤلفه های اصلی در ماتریس X که میانگین آن کم شده است، ماتریس ویژگی C بدست می آید.

$$C = P.X \quad (3)$$

<sup>۴</sup> Feed-Forward Neural Network


<sup>۵</sup> Annotation file

<sup>۶</sup> Kernel function

<sup>۷</sup> Radial basis function

<sup>۸</sup> Polynomial

<sup>۹</sup> Linear



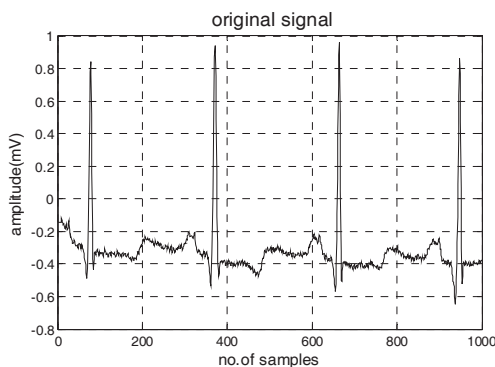
شبکه عصبی استفاده شده در این مقاله دارای یک لایه ورودی با ۱۲ گره (به تعداد ویژگی‌های هر ضربان)، یک لایه میانی با ۱۰ گره (تعداد ۱۰ با روش آزمون و خطا بدست آمده است) و یک لایه خروجی با ۵ گره (به تعداد کلاس‌های طبقه‌بندی) است. ابتدا شبکه توسط همان داده‌های آموزشی، آموزش داده می‌شود و سپس همان داده‌های تست به آن داده می‌شود.

### نتایج

روش‌های ذکر شده، با استفاده از نرم‌افزار MATLAB پیاده سازی و سیگنال‌های ECG مورد نیاز، از پایگاه داده MIT-BIH arrhythmia [۲۲]، تهیه شده است.

این پایگاه داده شامل ۴۸ سیگنال ECG دو کاناله است؛ هر سیگنال به طول ۳۰ دقیقه است و از ۴۷ مورد مطالعاتی بین سال‌های ۱۹۷۵-۱۹۷۹ بدست آمده‌اند. سیگنال‌ها با فرکانس ۳۶۰ هرتز نمونه‌برداری شده و با دقت ۱۱ بیت در محدوده ۱۰ میلی ولت ذخیره شده‌اند. هر ثبت توسط دو یا چند متخصص قلب علامت‌گذاری شده است.

شکل ۹ قسمتی از یک سیگنال ECG موجود در پایگاه داده را نشان می‌دهد.

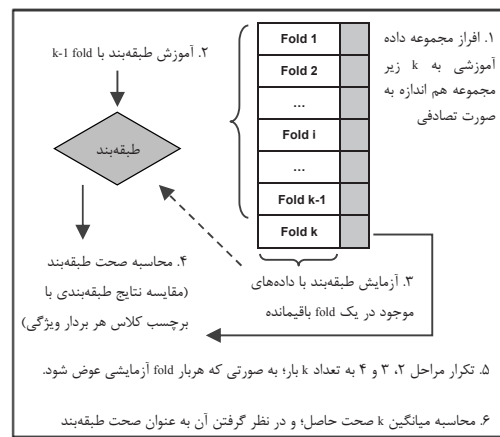


شکل ۱۰ سیگنال را پس از حذف نویزها، نشان می‌دهد.

SVM برای جداسازی چند کلاس نیز تعمیم داده شده است [۲۰]. رایج‌ترین روش‌های SVM چندکلاسه عبارتند از: یکی در مقابل همه (OAA) و یکی در مقابل یکی (OAO). در این روش‌ها ابتدا چندین طبقه‌بند دودویی ایجاد شده سپس نتایج آن‌ها با هم ترکیب می‌گردد.

هنگام استفاده از یک هسته، باید مقدار پارامترهای مربوط به آن به‌گونه‌ای انتخاب شود که خطای طبقه‌بند، در دسته‌بندی داده‌های جدید، کمترین مقدار ممکن باشد.

برای هسته RBF دو پارامتر  $c$  و  $\gamma$  وجود دارد. برای تعیین مقادیر بهینه این دو پارامتر، با روش grid-search مختلفی از زوج  $(c, \gamma)$  در نظر گرفته شده و به ازای هر زوج، صحت طبقه‌بند با روش اعتبار سنجی متقابل محاسبه شده؛ در نهایت زوجی از  $(c, \gamma)$  با بهترین صحت طبقه‌بندی، انتخاب می‌شود. روش اعتبار سنجی متقابل در شکل ۷ خلاصه شده است.



شکل ۷. مراحل انجام روش اعتبارسنجی متقابل

پس از یافتن مقادیر بهینه  $c$  و  $\gamma$ ، با این مقادیر و داده‌های آموزشی، طبقه‌بند ساخته می‌شود.

### طبقه‌بندی به روش FFNN

در این مقاله از یک شبکه عصبی FFNN، برای مقایسه با SVM استفاده شده است.

ساختار این نوع شبکه در شکل ۸ نمایش داده شده است. این شبکه‌ها از تعداد زیادی نورون به هم پیوسته تشکیل شده‌اند که لایه‌های ورودی، میانی و خروجی را تشکیل می‌دهند. انتشار سیگنال در این شبکه‌ها در مسیری رو به جلو است [۲۱].

<sup>۱۰</sup> One Against All

<sup>۱۱</sup> One Against One

<sup>۱۲</sup> k-fold cross validation

<sup>۱۳</sup> <https://www.physionet.org/physiobank/database/mitdb/>

از معیارهای ارزیابی عملکرد طبقه بندی، پارامتر صحت است؛ که با توجه به رابطه ۴ محاسبه می گردد.

$$ACC = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (4)$$

در رابطه فوق، TP تشخیص صحیح مثبت، TN تشخیص صحیح منفی، FP تشخیص اشتباه مثبت و FN تشخیص اشتباه منفی است.

در جدول ۲ نتایج طبقه بندی با هسته های مختلف SVM نشان داده شده است.

در روش اعتبارسنجی متقابل  $k = 10$  در نظر گرفته شده و مقدار پارامترها با استفاده از روش فوق، به ترتیب زیر انتخاب شده اند:

$$\gamma = 0.125, c = 128$$

در هسته چندجمله ای،  $n$  درجه چندجمله ای است. با توجه به جدول ۲، بهترین نتایج با هسته RBF حاصل شده است.

جزئیات نتایج طبقه بندی با RBF در جدول ۳ نمایش داده شده است.

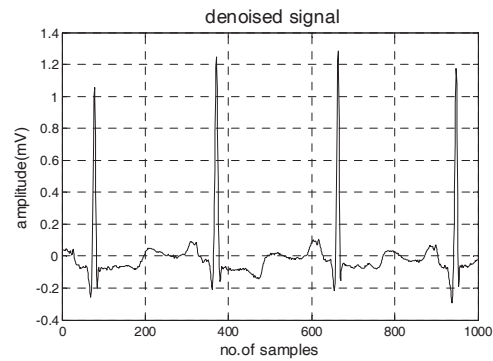
جدول ۳. نتایج طبقه بندی با SVM

	N	LBBS	RBSB	APB	PB
N	۹۷/۰۶	۰۰/۶۱	۰۰/۰۶	۰۲/۱۱	۰۰/۱۷
LBBS	۰۴/۵۰	۹۳/۰۰	۰۲/۰۰	۰۰/۵۰	۰۰/۰۰
RBSB	۰۲/۷۵	۰۲/۰۰	۹۳/۵۰	۰۱/۵۰	۰۰/۲۵
APB	۰۹/۶۹	۰۰/۰۰	۰۰/۲۶	۹۰/۰۵	۰۰/۰۰
PB	۰۰/۰۰	۰۰/۲۵	۰۰/۰۰	۰۰/۰۰	۹۹/۷۵
صحت کل	۹۵/۶۸				

مشاهده می شود که با استفاده از روش SVM، ۵ کلاس انتخاب شده، با صحت ۹۵/۶۸ درصد طبقه بندی شده است.

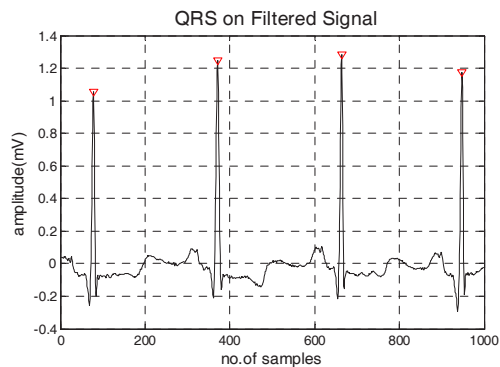
جدول ۴ نتایج طبقه بندی با FFNN را نشان می دهد. ۵ کلاس ذکر شده، با صحت ۹۰/۳۰ درصد طبقه بندی شده اند.

جدول ۵ نتایج هر دو طبقه بندی را در مقایسه با هم نشان می دهد. همانطور که از جدول مشاهده می شود، روش پیشنهادی با طبقه بندی SVM از کارایی بالاتری در مقایسه با روش FFNN برخوردار است.



شکل ۱۰. نمایش سیگنال پس از حذف نویز

در شکل ۱۱، موج های R که به روش Pan\_Tompkins استخراج شده اند، نمایش داده شده است.



شکل ۱۱. نمایش موج های R استخراج شده به روش Pan\_Tompkins

همانطور که دیده می شود، الگوریتم به خوبی توانسته موج های R را از سیگنال آشکار کند.

در جدول ۱ تعداد ضربان های استفاده شده از هر سیگنال برای تهیه داده های آموزشی و آزمایشی، بیان شده است.

برای پیاده سازی طبقه بندی SVM در محیط MATLAB از کتابخانه LIBSVM [۲۳] استفاده شده است.

جدول ۱. تعداد ضربان های آموزش و تست

نوع آریتمی	شماره سیگنال	آموزش	تست
N	100,101,103,105,108	۱۰۰	۱۰۰
	112,113,114,115,117	۱۰۰	۱۰۰
	121,122,123,202,205	۱۰۰	۱۰۰
	219,230, 234	۱۰۰	۱۰۰
LBBS	109, 111, 207, 214	۱۰۰	۱۰۰
RBSB	118, 124, 212, 231	۱۰۰	۱۰۰
APB	209, 222, 232	۱۰۰	۱۰۰
	220	۴۷	۴۷
PB	223	۳۵	۳۵
	102, 104, 107, 217	۱۰۰	۱۰۰
جمع		۳۳۸۲	۳۳۸۲

جدول ۲. مقایسه نتایج طبقه‌بندی با هسته‌های مختلف در طبقه‌بند SVM

		N	LBBB	RBBB	APB	PB	صحت
خطی		۹۹/۰۶	۴۲/۷۵	۸۸/۲۵	۳۱/۴۱	۹۹/۵۰	۸۳/۵۳
چند جمله‌ای	n=۱	۹۹/۱۷	۴۰/۷۵	۸۶/۷۵	۲۲/۵۱	۹۹/۵۰	۸۲/۱۷
	n=۲	۹۲/۰۶	۷۴/۰۰	۶۱/۵۰	۶۹/۸۹	۹۴/۲۵	۸۴/۰۶
	n=۳	۹۷/۸۳	۷۵/۵۰	۸۹/۰۰	۷۹/۰۶	۹۸/۵۰	۹۲/۱۰
	n=۴	۹۲/۴۴	۷۰/۷۵	۵۸/۰۰	۷۶/۱۸	۹۴/۷۵	۸۴/۲۴
تابع پایه شعاعی		۹۷/۰۶	۹۳/۰۰	۹۳/۵۰	۹۰/۰۵	۹۹/۷۵	۹۵/۶۸

در مرحله اول الگوریتم پیشنهادی، با استفاده از فیلتر IIR و موجک گسسته، نویزهای موجود در سیگنال، حذف شد. سپس موج‌های R با روش Pan\_Tompkins استخراج و با استفاده از آن، سیگنال به اندازه ۲۰۰ نمونه قطعه‌بندی شد و ویژگی‌های هر قطعه با تبدیل موجک گسسته استخراج گردید؛ از تبدیل PCA برای کاهش ابعاد و دور ریختن اطلاعات اضافی، استفاده شد و نهایتاً ۱۲ ویژگی به ازای هر ضربان انتخاب شد. در مرحله آخر، ویژگی‌ها با استفاده از الگوریتم پیشنهادی با طبقه‌بند SVM و روش FFNN دسته‌بندی شدند. روش پیشنهادی با صحت ۹۵/۶۸ درصد و روش FFNN با صحت ۹۰/۳۰ درصد، ۵ کلاس را طبقه‌بندی کردند. مقایسه کمی نشان می‌دهد که الگوریتم پیشنهادی با طبقه‌بند SVM برای طبقه‌بندی آریتمی‌های قلبی از کارایی بالاتری برخوردار است.

### مراجع

- [1] M. S. Chavan, R. Agarwala, and M. Uplane, "Suppression of baseline wander and power line interference in ECG using digital IIR filter," *International Journal of Circuits, Systems And Signal Processing*, vol. 2, pp. 356-65, 2008.
- [2] H. K. Gupta, R. Vijay, and N. Gupta, "designing and implementation of algorithms on Matlab for Adaptive noise cancellation from ECG signal," *International journal of computer applications*, vol. 71, 2013.
- [3] G. Georgieva-Tsaneva and K. Tcheshmedjiev, "Denoising of electrocardiogram data with methods of wavelet transform," in *International Conference on Computer Systems and Technologies*, 2013, pp. 9-16.
- [4] N. M. Arzeno, Z.-D. Deng, and C.-S. Poon, "Analysis of first-derivative based QRS detection algorithms," *IEEE Transactions on Biomedical Engineering*, vol. 55, pp. 478-484, 2008.

جدول ۴. نتایج طبقه‌بندی با FFNN

	N	LBBB	RBBB	APB	PB
N	۹۷/۱۱	۱۲/۷۵	۰۴/۲۵	۴۱/۶۲	۰۰/۲۵
LBBB	۰۰/۵۰	۸۳/۷۵	۰۵/۵۰	۰۱/۰۵	۰۰/۰۰
RBBB	۰۰/۷۲	۰۱/۰۰	۸۸/۵۰	۰۰/۲۶	۰۰/۰۰
APB	۰۱/۲۲	۰۱/۰۰	۰۱/۷۵	۵۷/۰۷	۰۰/۰۰
PB	۰۰/۴۴	۰۱/۵۰	۰۰/۰۰	۰۰/۰۰	۹۹/۷۵
صحت کل	۹۰/۳۰				

جدول ۵. مقایسه نتایج طبقه‌بندی با هر دو روش

	SVM	FFNN
N	۹۷/۰۶	۹۷/۱۱
LBBB	۹۳/۰۰	۸۳/۷۵
RBBB	۹۳/۵۰	۸۸/۵۰
APB	۹۰/۰۵	۵۷/۰۷
PB	۹۹/۷۵	۹۹/۷۵
صحت کل	۹۵/۶۸	۹۰/۳۰

### نتیجه گیری

تشخیص خودکار آریتمی‌های قلبی از روی سیگنال‌های ثبت‌شده‌ی قلبی بیماران به دلایلی نظیر طولانی بودن ثبت‌های سیگنال و خطاهای احتمالی پزشکان از اهمیت بسزایی برخوردار است.

در این مقاله به منظور تشخیص خودکار آریتمی‌های قلبی از روی سیگنال ECG، ترکیب استخراج ویژگی‌های تبدیل موجک و طبقه‌بند SVM پیشنهاد شده است. به منظور مقایسه‌ی عملکرد الگوریتم پیشنهادی نتایج با طبقه‌بند شبکه عصبی به صورت کمی مقایسه شده است. در این مقاله، دو روش برای تشخیص خودکار آریتمی‌های قلبی از روی سیگنال ECG، بررسی، پیاده‌سازی و مقایسه شد.

- Systems with Applications*, vol. 34, pp. 2841-2846, 2008.
- [15] D. Sambhu and A. Umesh, "Automatic Classification of ECG Signals with Features Extracted Using Wavelet Transform and Support Vector Machines," *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*, vol. 2, pp. 235-241, 2013.
- [16] E. Pasolli and F. Melgani, "Active learning methods for electrocardiographic signal classification," *IEEE Transactions on Information Technology in Biomedicine*, vol. 14, pp. 1405-1416, 2010.
- [17] M. Al Rahhal, Y. Bazi, H. AlHichri, N. Alajlan, F. Melgani, and R. Yager, "Deep learning approach for active classification of electrocardiogram signals," *Information Sciences*, vol. 345, pp. 340-354, 2016.
- [18] A. Harkat, R. Benzid, and L. Saidi, "Features extraction and classification of ECG beats using CWT combined to RBF neural network optimized by cuckoo search via levy flight," in *2015 4th International Conference on Electrical Engineering (ICEE)*, 2015, pp. 1-4.
- [19] L. Sörnmo and P. Laguna, "Electrocardiogram (ECG) signal processing," *Wiley Encyclopedia of Biomedical Engineering*, 2006.
- [20] C.-W. Hsu and C.-J. Lin, "A comparison of methods for multiclass support vector machines," *IEEE transactions on Neural Networks*, vol. 13, pp. 415-425, 2002.
- [21] M. A. Nielsen, *Neural Networks and Deep Learning*: Determination Press, 2015.
- [22] A. L. Goldberger, L. A. Amaral, L. Glass, J. M. Hausdorff, P. C. Ivanov, R. G. Mark, *et al.*, "Physiobank, physiotoolkit, and physionet components of a new research resource for complex physiologic signals," *Circulation*, vol. 101, pp. e215-e220, 2000.
- [23] C.-C. Chang and C.-J. Lin, "LIBSVM: a library for support vector machines," *ACM Transactions on Intelligent Systems and Technology (TIST)*, vol. 2, p. 27, 2011.
- [5] J. Pan and W. J. Tompkins, "A real-time QRS detection algorithm," *IEEE transactions on biomedical engineering*, pp. 230-236, 1985.
- [6] P. Sasikala and R. Wahidabanu, "Robust R peak and QRS detection in electrocardiogram using wavelet transform," *International Journal of Advanced Computer Science and Applications-IJACSA*, vol. 1, pp. 48-53, 2010.
- [7] U. Kunzmann, G. Wagner, J. Schöchlin, and A. Bolz, "Parameter extraction of ECG signals in real-time," *Biomedizinische Technik/Biomedical Engineering*, vol. 47, pp. 875-878, 2002.
- [8] L. Kanaan, D. Merheb, M. Kallas, C. Francis, H. Amoud, and P. Honeine, "PCA and KPCA of ECG signals with binary SVM classification," in *2011 IEEE Workshop on Signal Processing Systems (SiPS)*, 2011, pp. 344-348.
- [9] M. Lagerholm, C. Peterson, G. Braccini, L. Edenbrandt, and L. Sörnmo, "Clustering ECG complexes using Hermite functions and self-organizing maps," *IEEE Transactions on Biomedical Engineering*, vol. 47, pp. 838-848, 2000.
- [10] C.-H. Lin, "Frequency-domain features for ECG beat discrimination using grey relational analysis-based classifier," *Computers & Mathematics with Applications*, vol. 55, pp. 680-690, 2008.
- [11] R. J. Martis, U. R. Acharya, and L. C. Min, "ECG beat classification using PCA, LDA, ICA and discrete wavelet transform," *Biomedical Signal Processing and Control*, vol. 8, pp. 437-448, 2013.
- [12] T. Ince, S. Kiranyaz, and M. Gabbouj, "A generic and robust system for automated patient-specific classification of ECG signals," *IEEE Transactions on Biomedical Engineering*, vol. 56, pp. 1415-1426, 2009.
- [13] M. Llamedo and J. P. Martínez, "Heartbeat classification using feature selection driven by database generalization criteria," *IEEE Transactions on Biomedical Engineering*, vol. 58, pp. 616-625, 2011.
- [14] S.-N. Yu and K.-T. Chou, "Integration of independent component analysis and neural networks for ECG beat classification," *Expert*