



ارائه روشی جدید مبتنی بر شبکه عصبی مصنوعی برای طبقه‌بندی سیگنال‌های قلبی

حبیب جبارپورهریس، دانشجوی کارشناسی ارشد، گروه مهندسی کامپیوتر، واحد تهران جنوب، دانشگاه

آزاد اسلامی، تهران، ایران

h.jabbarpour.h@gmail.com

راضیه فرازکیش، عضو هیئت علمی، گروه مهندسی کامپیوتر، واحد تهران جنوب، دانشگاه آزاد اسلامی،

تهران، ایران

r.farazkish@srbiau.ac.ir

چکیده

روش‌های تشخیص بیماری‌های قلبی توسط پزشکان خطراتی برای بیماران به همراه داشته و همچنین از دقت کافی برخوردار نمی‌باشند. به همین دلیل تشخیص زودهنگام بیماری‌های قلبی با بهره‌گیری از تحلیل سیگنال ضربان قلب می‌تواند راه‌گشای هرچه بهتر در تشخیص و درمان به موقع بیماری باشد. در این تحقیق سعی بر آن است که با استفاده از شبکه عصبی پرسپترون چندلایه طبقه‌بندی سیگنال‌های قلبی صورت گیرد. برای این منظور در مرحله پیش‌پردازش ابتدا سیگنال‌های قلبی از سایت فیزیونت جمع‌آوری شده و نویزهای فرکانس بالا و پایین از سیگنال حذف و استخراج ویژگی با استفاده از تبدیلات موجک انجام شد و در نهایت طبقه‌بندی سیگنال‌های قلبی با استفاده از شبکه عصبی پرسپترون چندلایه انجام و نتایج با شبکه عصبی پایه‌ای - شعاعی مقایسه شده است. نتایج طبقه‌بندی شبکه عصبی پرسپترون چندلایه حاکی از دقت 98.3% در طبقه‌بندی سیگنال‌های قلبی است.

کلیدواژه‌ها: سیگنال‌های قلبی، طبقه‌بندی، شبکه عصبی پرسپترون چندلایه، شبکه عصبی پایه‌ای - شعاعی.



1- مقدمه

سیستم قلبی و عروقی انسان ضعیف و آریتمی قلب در سنین بالا مستعدتر می‌شود. یک آریتمی، یک ضربان قلب غیرطبیعی است که می‌تواند تهدیدکننده زندگی افراد باشد (Yang, 2014). تشخیص نادرست و یا دیر هنگام نارسایی‌های قلبی می‌تواند سالانه به بروز خطرات جدی و یا حتی مرگ برخی از افراد منجر شود. بررسی دقیق نارسایی‌های قلبی مستلزم تهیه نمونه‌های متعدد و بررسی آنها توسط پزشک ماهر می‌باشد که این نیز به نوبه خود وقت‌گیر بوده و نیازمند صرف زمان زیادی از سوی متخصص می‌باشد از این رو احتمال خطا در هنگام تشخیص نیز افزایش می‌یابد (Alickovic, 2015). دینامیک سیستم اعصاب خودکار متناسب با حالات روانی مختلف از جمله استرس دستخوش تغییرات شده و از این رو می‌توان به وسیله تحلیل سیگنال‌های مرتبط با آن، فعالیت سیستم اعصاب خودکار را آشکار کرد (Saminu, 2014). پیچیدگی و طبیعت غیرایستاد صدای قلب، پردازش آن به یک روش خودکار را به عنوان یک مسئله مهم در تجزیه و تحلیل سیگنال‌ها مبدل کرده است (Das, 2014). تشخیص آریتمی‌های¹ قلبی با تجزیه و تحلیل و تفسیر سیگنال‌های قلبی صورت می‌گیرد. سیگنال‌های الکتروکاردیوگرام (ECG²) اطلاعات مهم و قابل توجهی را برای متخصصین قلب و عروق به منظور تشخیص بیماری‌های قلبی فراهم می‌کنند به تبع آن، انجام فرآیند تشخیص الگو به جهت تشخیص ویژگی و طبقه‌بندی سیگنال ECG، قابل توجه می‌باشد (Vafaie, 2014). در این پژوهش قصد داریم روشی دقیق و سریع برای تشخیص و طبقه‌بندی سیگنال‌های ECG بر اساس شبکه عصبی مصنوعی پیشنهاد دهیم. ادامه ساختار این مقاله بدین ترتیب است که در بخش دوم مروری بر پیشینه تحقیق خواهد شد. در بخش سوم شبکه‌های عصبی پرسپترون چندلایه و پایه‌ای - شعاعی مرور می‌شوند. در بخش چهارم مدل پیشنهادی ارائه و نتایج طبقه‌بندی سیگنال‌های قلبی توسط شبکه عصبی پرسپترون چندلایه با شبکه عصبی پایه‌ای - شعاعی بر اساس معیارهای خطا و کارایی استاندارد بیان می‌شوند و در نهایت در بخش آخر نتیجه‌گیری بیان می‌شود.

2- پیشینه تحقیق

Korürek و همکاران در سال 2010 در مقاله‌ای تحت عنوان طبقه‌بندی ضربان ECG با استفاده از الگوریتم ازدحام ذرات و شبکه عصبی پایه‌ای - شعاعی به ارائه روشی RBFNN در این زمینه پرداختند. در این حوزه می‌توان به شش نوع ضربان قلبی متفاوت اشاره کرد که هر کدام دارای خصوصیات خاص خود هستند تمامی این ضربان‌ها از پایگاه داده Arrhythmia MIT-BIH به دست آمده‌اند. از این بین چهار ویژگی مورفولوژیک از هر کدام از ضربان‌ها پس از پیش‌پردازش رکوردهای موردنظر به دست آمد. در مرحله طبقه‌بندی ویژگی‌های استخراجی از روش RBFNN که در آن الگوریتم ازدحام ذرات نیز به کار رفته، استفاده شد. آزمایشات متعدد انجام گرفته بر روی مجموعه تست و مشاهدات ناشی از آن نشان می‌دهد که روش پیشنهادی ضربان‌های ECG همراه با اندازه کوچک شبکه بدون ایجاد هیچ آریتمی بر روی عملکرد شبکه عصبی به خوبی طبقه‌بندی می‌کند (Korürek, 2010). Barni و همکاران در سال 2011 در مقاله‌ای با نام طبقه‌بندی با حفظ حریم خصوصی ضربان‌های ECG با استفاده از برنامه‌های branching و شبکه‌های عصبی به ارائه روشی در این زمینه پرداختند. در این پژوهش بر روی توسعه یک سیستم تشخیص خودکار با

¹ Arrhythmia² ElectroCardioGram=ECG



حفظ حریم خصوصی بیمار تأکید شده است. در این سیستم یک سرور از راه دور سیگنال دریافتی از بیمار را بدون گرفتن هیچ اطلاعاتی از خود سیگنال و نتیجه نهایی طبقه‌بندی، پردازش می‌کند. در اینجا دو روش برای طبقه‌بندی ایمن سیگنال‌های ECG ارائه شد. اولین روش براساس برنامه‌های **branching** که نوع خاصی از درخت تصمیم است، عمل می‌کند و دومین روش مبتنی بر شبکه‌های عصبی است برای محافظت اطلاعات داده‌ها به صورت رمزگذاری شده درآمدند لذا یک روش رمزنگاری اولیه استفاده شد که خللی در عملکرد دو روش از این طریق از لحاظ پیچیدگی محاسباتی و الزامات مربوط به انتقال داده ایجاد نشود. سیستم‌های پیشنهادی نشان دادند که وظایف پیچیده را که از آن جمله طبقه‌بندی سیگنال‌های ECG است به خوبی انجام می‌دهند. همچنین استانداردهای امنیتی مربوط به حفظ حریم خصوصی بیمار نیز در این سیستم‌ها به خوبی رعایت شد (Barni, 2011). Wang و همکاران در سال 2013 در مقاله‌ای تحت عنوان طبقه‌بندی سیگنال‌های ECG با استفاده از شبکه عصبی احتمالی و روش کاهش ویژگی پرداختند. در این پژوهش روش‌های PCA و LDA برای کاهش ویژگی‌ها باهم ترکیب شدند همچنین برای طبقه‌بندی ضربان‌های ECG به هشت نوع مختلف از یک شبکه عصبی احتمالی PNN استفاده شد و هر کدام از این ضربان‌های ECG خود متشکل از 200 نمونه با نرخ 360 هرتز هستند و یک قله R از هر سیگنال ECG استخراج شد. روش استفاده شده برای کاهش ویژگی برای یافتن ویژگی‌های مهم سیگنال‌های ECG استفاده شد و از این طریق موجب افزایش دقت طبقه‌بند PNN شد. دقت ارائه شده توسط روش پیشنهادی در این مقاله در حدود 99.71% است و نتایج آزمایشگاهی مؤید ترکیب مؤفقت‌آمیز طبقه‌بند PNN با روش کاهش ویژگی LDA-PCA است (Wang, 2013). Martis و همکاران در سال 2013 در مقاله‌ای با نام طبقه‌بندی سیگنال‌های ECG با استفاده از روش ترکیبی LDA, PCAT LDA و تبدیلات گسسته موجک پرداختند. با استفاده از تبدیلات گسسته موجک می‌توان الگوهای معنادار نهفته در سیگنال‌های ECG را آشکار کرد از این رو در این پژوهش 5 نوع مختلف از سیگنال‌های ECG مطابق با مؤسسه AAMI مدنظر قرار گرفتند. در اینجا از سه روش PCA و LDA و ICA به طور مستقل برای کاهش ویژگی استفاده شد همچنین از زیرباندهای DWT برای کاهش ویژگی همراه این سه روش استفاده شد پس از کاهش ویژگی، ویژگی‌های موردنظر به یک ماشین بردار پشتیبان و همچنین به یک PNN با نرخ گسترش 0.03 داده شد که در اینجا ویژگی‌های ارائه شده توسط ICA در ترکیب با شبکه PNN دقت بالاتری را نسبت به LDA و PCA ارائه دادند به طور کلی با استفاده از روش‌های بالا به ترتیب دقتی برابر با 99.97%, 99.83%, 99.21% و 99.28% به دست آمد (Martis, 2013). Melin و همکاران در سال 2014 در مقاله‌ای تحت عنوان مدل شبکه عصبی براساس الگوریتم LVQ برای طبقه‌بندی چندکلاسی سیگنال‌های ECG به ارائه روشی در این زمینه پرداختند. در این پژوهش از پایگاه داده MIT-BIH استفاده شد. در این مقاله سه مدل مختلف به صورت ماژولار برای طبقه‌بندی توسعه داده شدند. در مقایسه با دیگر روش‌های طبقه‌بندی که بر روی همین پایگاه داده انجام شد روش پیشنهادی نتایج بسیار خوبی را تولید می‌کند از آنجا که نتایج شبیه‌سازی به صورت نموداری ارائه شد و علاوه بر آن تست آماری اجرا شده نشان می‌دهد که سه معماری ارائه شده در این حوزه نتایج بسیار نزدیکی به هم دارند (Melin, 2014). Thomas و همکاران در سال 2015 در مقاله‌ای تحت عنوان طبقه‌بندی خودکار سیگنال‌های ECG با استفاده از موجک ترکیبی دوگانه به ارائه روشی در این زمینه



پرداختند. در این مقاله از روش استخراج ویژگی¹ DTCWT برای استخراج ویژگی استفاده شد. مجموعه ویژگی‌ها مشتمل بر ضرایب موجک بوده که از سطح 4 و 5 فرایند تجزیه سیگنال QRS توسط موجک در ترکیب با چهار ویژگی دیگر یعنی قدرت AC، کشیدگی و چولگی و اطلاعات زمانی از این سیگنال استخراج شد. این ویژگی‌ها با استفاده از یک شبکه عصبی پس‌انتشار طبقه‌بندی شدند. کارایی مجموعه ویژگی‌های پیشنهادی با ویژگی‌های آماری استخراج شده از زیرباند های به‌دست آمده پس از تجزیه QRS با استفاده از DWT و DTCWT مقایسه شدند. نتایج آزمایشگاهی نشان می‌دهد که استخراج ویژگی مبتنی بر DTCWT و DWT و طبقه‌بندی صورت گرفته با شبکه عصبی پس‌انتشار برای هر یک از مجموعه ویژگی‌های استخراج شده از هر کدام از روش‌های DWT و DTCWT به‌دقت طبقه‌بندی به ترتیب 91.23% و 94.26% دست یافته شده است که حاکی از برتری DTCWT در ترکیب با شبکه عصبی BP دارد (Thomas, 2015). Kiranyaz و همکاران در سال 2016 در مقاله‌ای تحت عنوان طبقه‌بندی ECG بیماران با استفاده از شبکه‌های عصبی کانولوشن به ارائه روشی در این زمینه پرداختند. در این مقاله یک پیاده‌سازی تطبیقی از شبکه‌های عصبی کانولوشن تک‌بعدی به‌کار گرفته شد تا از این طریق دو بلوک فرایند طبقه‌بندی ECG به یک بلوک استخراج ویژگی و طبقه‌بندی تبدیل شود در نتیجه برای هر بیمار به‌صورت مجزا یک CNN² با استفاده از داده‌های آموزشی مختص هر بیمار آموزش داده شد. زیرا چنین استخراج ویژگی می‌تواند عملکرد طبقه‌بندی را بهبود دهد همچنین این نوع استخراج ویژگی تحت تأثیر دستکاری‌های صورت گرفته توسط انسان برای استخراج ویژگی نیست زمانی که یک CNN برای هر بیمار آموزش داده می‌شود می‌تواند برای جریان‌های داده‌ای طولانی از ECG بیمار برای طبقه‌بندی به‌صورت سریع و با دقت بالا استفاده شود که در نتیجه می‌تواند برای مانیتور کردن امواج ECG به‌صورت زمان‌واقعی مناسب بوده و می‌تواند به‌عنوان یک سیستم پیش‌هشدار سریع بر روی وسایل پوسیدنی سبک‌وزن نصب شود. نتایج آزمایشگاهی نشان می‌دهد که روش پیشنهادی در مقایسه با روش‌های نوین دیگر بر روی پایگاه داده MIT-BIH دارای عملکرد بهتری در طبقه‌بندی ضربان‌های ECG همچون *supraventricular ectopic* و ضربان‌های *ventricular ectopic* است. همچنین از این روش برای طبقه‌بندی رکوردهای ECG طولانی و ممتد همچون *holter registers* با سرعت و دقت زیاد می‌توان استفاده کرد همچنین با توجه به طراحی ساده و ثابت سیستم پیشنهادی از آن می‌توان برای طبقه‌بندی دیگر پایگاه‌داده‌های ECG نیز استفاده کرد (Kiranyaz, 2016). Rahhal و همکاران در سال 2016 به طبقه‌بندی سیگنال‌های ECG با استفاده از روش یادگیری عمیق پرداختند. در این مقاله یک روش مناسب نمایش ویژگی‌های داده‌های ECG با استفاده از روش حذف نویز SDAE ارائه شده است. بعد از مرحله یادگیری ویژگی، یک لایه رگرسیون به بالای لایه مخفی نمایش نتایج شبکه عصبی عمیق اضافه شده است. در طول فاز آموزش، الگوریتم آموزشی اجازه دارد در هر تکرار برچسب مناسب‌ترین ضربان ECG در نمونه آزمایش را برای به‌هنگام‌سازی وزن‌های شبکه عصبی عمیق استفاده کند. در آزمایشات برای ارزیابی روش پیشنهادی از پایگاه داده MIT استفاده شده است. نتایج بدست آمده نشان می‌دهد که روش پیشنهادی دقت و سرعت تشخیص را در مقایسه با روش *state-of-the-art* بهبود داده است (Rahhal, 2016). Acharya و همکاران در سال 2017 به کشف اتوماتیک آریتمی‌ها با استفاده از فواصل زمانی مختلف بخش‌های تاکیکاردی ECG با شبکه عصبی کانولوشن

¹ Dual Tree Complex Wavelet Transform

² Convolutional Neural Network



پرداختند. در این مقاله یک سیستم تشخیص به کمک کامپیوتر به نام CAD معرفی شده است. روش CAD اطمینان می‌دهد که ارزیابی سیگنال‌های ECG با دقت بالایی انجام می‌شود. در این مقاله شبکه عصبی کانولوشن برای تشخیص اتوماتیک سیگنال‌های مختلف ECG ارائه شده است. الگوریتم پیشنهادی از 11 لایه عمیق CNN و 4 نورون در لایه خروجی تشکیل شده است. در این تحقیق دقت 94.9 درصد حاصل شده است (Acharya, 2017). Zhang و همکاران در سال 2017 به طبقه‌بندی ECG بیماران براساس شبکه‌های عصبی بازگشتی و تکنیک خوشه‌بندی پرداختند. از شبکه عصبی بازگشتی برای یادگیری نقاط وابسته سیگنال ECG و طبقه‌بندی ضربان قلب با نرخ متفاوت استفاده شده است. ویژگی‌های مورفولوژی، ضربان و موج T به عنوان ویژگی‌های یادگیر به شبکه عصبی بازگشتی اعمال شده است. از روش خوشه‌بندی مبتنی بر تراکم برای پیدا کردن ضربان‌های مناسب به عنوان داده‌های آموزشی استفاده شده است. ارزیابی بر روی پایگاه داده MIT انجام شده است و نشان از کارایی روش پیشنهادی دارد (Zhang, 2017).

3- مروری بر شبکه‌های عصبی مصنوعی

در این بخش ابتدا شبکه عصبی پایه‌ای - شعاعی و در ادامه شبکه عصبی پرسپترون چندلایه بیان می‌شوند.

3-1- شبکه عصبی پایه‌ای - شعاعی

شبکه‌های عصبی به‌عنوان یک تکنولوژی کاربردی ظاهر شده‌اند که به صورت موفقیت‌آمیزی در زمینه‌های متفاوت به کار برده می‌شوند. مهم‌ترین مزیت شبکه عصبی قابلیت خودتطبیقی، خودسازماندهی و عملیات بلادرنگ و ... است. شبکه عصبی پایه‌ای شعاعی به‌طور گسترده‌ای برای تخمین غیرپارامتریک توابع چندبندی از طریق مجموعه‌ای محدود از اطلاعات آموزشی به کار می‌رود. شبکه‌های عصبی شعاعی به‌واسطه آموزش سریع و فراگیر، بسیار جالب و مفید هستند و مورد توجه خاصی قرار گرفته‌اند. شبکه‌های عصبی پایه‌ای - شعاعی تقریب‌سازی هر تابع پیوسته و با هر درجه دقت می‌باشند. نکته بسیار جالب آن است که این شبکه‌ها تنها با داشتن یک لایه مخفی، دارای چنین خاصیتی هستند. شبکه‌های پایه‌ای - شعاعی بیش‌ترین الهام را از تکنیک‌های آماری طبقه‌بندی الگوها گرفته‌اند که اساساً به‌عنوان گونه‌ای از شبکه‌های عصبی، حیاتی‌نو یافته‌اند و مزیت عمده آن‌ها طبقه‌بندی الگوهایی با فضای غیرخطی است (Liu, 2013).

در شبکه عصبی پایه‌ای - شعاعی، لایه ورودی فقط یک لایه ورودی است و در آن هیچ پردازشی صورت نمی‌گیرد. لایه دوم یا لایه پنهان، یک انطباق غیرخطی مابین فضای ورودی و یک فضای معمولاً با بُعد بزرگ‌تر برقرار می‌کند و نقش مهمی در تبدیل الگوهای غیرخطی به الگوهای تفکیک‌پذیر خطی دارد. سرانجام لایه سوم، جمع وزنی را به همراه یک خروجی خطی تولید می‌کند. در صورتی که از این شبکه عصبی برای تقریب تابع استفاده شود، چنین خروجی‌ای مفید خواهد بود ولی در صورتی که نیاز باشد طبقه‌بندی الگوها انجام شود، آن‌گاه یک محدودکننده سخت یا یک تابع سیگنوید را می‌توان بر روی عصب‌های خروجی قرار داد تا مقادیر خروجی 0 یا 1 تولید شوند (Liu, 2013).

همان‌طور که از توضیحات بالا مشخص می‌شود خصوصیات منحصربفرد این شبکه، پردازشی است که در لایه پنهان انجام می‌گیرد. تابع لایه پنهان دارای رابطه‌ای مطابق با رابطه (1) است:

$$f(x) = \sum_{i=1}^p w_i \varphi(Xc_i - x) \quad (1)$$



که در آن p تعداد توابع شعاعی، w_i وزن نرون i ام، Xc_i مرکز ثقل نرون i ام، x بردار ورودی و ϕ تابع شعاعی است. رابطه (1) نشان می‌دهد که برای تقریب تابع f از p تابع شعاعی که دارای مراکز ثقل Xc_i هستند استفاده می‌شود. نماد $\|\cdot\|$ تابع فاصله در فضای R^n است که معمولاً فاصله اقلیدسی انتخاب می‌شود. از آنجایی که منحنی نمایش تابع‌های پایه‌ای شعاعی به صورت شعاعی متقارن است، نرون‌های لایه مخفی به نرون‌های تابع شعاعی معروفند. تابع معروف در شبکه‌های شعاعی همان تابع گوسی یا نمایی است که در رابطه (2) مشخص شده است (Liu, 2013).

$$\phi(r) = e^{-\frac{r^2}{2\sigma^2}} \quad c > 0 \quad r \in R \quad (2)$$

که در آن $r = \|x - Xc_i\|$ است و σ فاکتور عرض هسته است. دلیل انتخاب تابع نمایی گوسی به عنوان تابع پاسخ نرون‌ها در شبکه عصبی این است که تابع نمایی جزء گروهی از توابعی است که دارای بهترین خواص در تقریب‌سازی هستند (Liu, 2013).

3-2- شبکه عصبی پرسپترون چندلایه

شبکه‌های عصبی به عنوان یک تکنولوژی کاربردی ظاهر شده‌اند که به صورت موفقیت‌آمیزی در زمینه‌های متفاوت به کار برده می‌شوند. مهم‌ترین مزیت شبکه عصبی قابلیت خودتطبیقی، خودسازماندهی و عملیات بلادرنگ و ... است. ساختار این شبکه شامل یک لایه ورودی، یک لایه میانی و یک لایه خروجی است. در هر لایه، یک یا چند عنصر پردازش‌گر (نرون)، وجود دارد که با تمامی نرون‌های لایه بعدی با اتصالات وزن‌دار، به هم مربوط می‌شوند. تعداد نرون‌های لایه‌های ورودی و خروجی، بستگی به تعداد متغیرهای ورودی و خروجی مدل دارد؛ ولی انتخاب تعداد نرون‌های لایه میانی به صورت سعی و خطا تعیین می‌شود که در مسأله ما معمولاً بهترین جواب تشخیص هویت با تعداد نرون‌های 10 در لایه پنهان به دست می‌آید (Kruse, 2013). در شبکه‌های عصبی، نرون‌های هر لایه، به کلیه نرون‌های لایه قبل، از طریق یک اتصال جهت‌دار، مرتبط می‌شوند. به هر یک از این اتصالات، وزنی داده می‌شود که مقدار آن، تعیین‌کننده تأثیر هر نرون روی نرون لایه خروجی است. مجموع وزنی مقادیر ورودی به هر نرون، محاسبه و در یک تابع ریاضی، قرار می‌گیرد و خروجی نرون از طریق این تابع، محاسبه می‌شود. این تابع ریاضی را اصطلاحاً تابع فعال‌سازی می‌گویند. توابع سیگموئیدی و خطی، رایج‌ترین توابع مورد استفاده برای شبکه‌های چندلایه پیش‌رونده هستند. در این تحقیق از تابع تانژانت هایپربولیک در نرون‌های لایه پنهان و نرون‌های لایه خروجی استفاده شده است. وزن‌های ارتباط‌دهنده نرون‌های شبکه، با آموزش تعیین می‌شوند. الگوریتم‌های بهینه‌سازی هوشمند یکی از تکنیک‌های بهینه‌سازی قدرتمند هستند که می‌توانند دستیابی به وزن‌های بهینه‌شده در شبکه عصبی را میسر سازند (Kruse, 2013).

4- روش پیشنهادی

طبقه‌بندی سیگنال‌های قلبی شامل پنج مرحله است. در پیش‌پردازش (حذف نویز فرکانس بالا، حذف نویز فرکانس پایین و استخراج ویژگی) و در پس‌پردازش از شبکه‌های عصبی پرسپترون چندلایه و پایه‌ای-شعاعی استفاده می‌شود. در این بخش مراحل تحقیق بیان می‌شود.



4-1- جمع آوری سیگنال های قلب

در این تحقیق از پایگاه داده فیزیوت استفاده شده است که در اکثر تحقیقات از آن استفاده شده است. این پایگاه داده شامل 2026 سیگنال قلبی است که از 80% سیگنال ها برای آموزش و از 20% باقی مانده در جهت آزمایش استفاده شده است.

4-2- حذف نویز فرکانس بالا با روش ساویتری و گولای

روش هموارسازی نمونه به وسیله ساویتری و گولای پیشنهاد شده است که بر اساس تقریب چندجمله ای حداقل مجذور محلی می باشد. با تقریب زدن یک گروه از $x[n]$ نمونه های نویز $2m+1$ به وسیله چندجمله ای $P(n) = \sum_{k=0}^M a_k n^k$ کوچک سازی خطا مدنظر می باشد. با انتخاب بردار مناسب $a = [a_0, a_1, \dots, a_n]$ هر گروه ورودی مدنظر دارای نمونه های M در اطراف نقطه مرکزی شان می باشد یا $x = [x_{-M}, x_{-M+1}, \dots, x_M]$ نمونه های خروجی $y[n]$ برای هر یک از مجموعه های ورودی x به وسیله حلقه گسسته $[n] = \sum_{m=-M}^M -mh[M]x[n - M]$ که پاسخ ضربه محدود $h(0)$ برای تقریب چندجمله ای حداقل مجذور مناسب می باشد. بردار a می تواند در رابطه (3) محاسبه شود (Savitzky, 1964).

$$a = (A^T A)^{-1} A^T X = HX \quad (3)$$

که ماتریس $-M \leq n \leq M$ and $A = \{n^i\}$, $i=0,1,\dots,N$ است. برای محاسبه پاسخ ضربه، $x = d[0.0, \dots, 0.1]$ قرار می دهیم و این بردار را به دست می آوریم.

$$a^3 = (A^T A)^{-1} A^T d \quad (4)$$

اکنون ردیف O^{th} ماتریس:

$$H = (A^T A)^{-1} A^T \quad (3)$$

$[h_0, -M, h_0-M+1, \dots, h_0, 0, \dots, h_0, M-1, h_0, M]$ می باشد که برابر با $[\tilde{P}(-M), \tilde{P}(-M+1), \dots, \tilde{P}(0), \dots, \tilde{P}(M)]$ چندجمله ای می باشد که d را با خطای حداقل مجذور تقریب می زند. از این رو، $h[-h] = \tilde{P}(0)$ است. انتخاب M و N برای داشتن تقریب و هموارسازی داده و نویز مهم می باشد. در این تحقیق درجه چندجمله ای 5 و تعداد نقاط برای آن 21 در نظر گرفته شده است (Savitzky, 1964).

4-3- حذف نویز فرکانس پایین

در این حالت یک چندجمله ای درجه هفت از سیگنال عبور داده و ضرایب چندجمله ای تعیین می شود در این وضعیت حاصل چندجمله ای از سیگنال کم می شود که نتیجه آن حذف نویز فرکانس پایین از سیگنال است.

4-4- استخراج ویژگی با استفاده از تبدیلات موجک

تبدیلات موجک¹ از جمله ابزارهایی هستند که کاربردهای فراوانی در شاخه های مختلف علمی و مهندسی، به ویژه هوش مصنوعی، یادگیری ماشینی، پیش بینی سری زمانی، استخراج ویژگی و بازشناسی الگو دارد. تئوری موجکها در واقع تعمیمی بر تئوری تبدیلات و سری های فوریه است و ضعف های آنالیز فوریه در عملکرد موضعی و مدل سازی رفتارهای کوتاه مدت را، جبران می نماید. معمولاً سیگنال ECG ترکیبی است از یک

¹ Wavelet



سیگنال و یک تداخل که ممکن است تفسیر کامپیوتری را پیچیده سازد، این تداخلها که اکثراً ناشی از حرکات بدن و چشم می باشد باعث ایجاد خطا در ثبت سیگنال و همچنین تحلیل آن می شود و می تواند کاربرد سیگنال ECG را تا حد زیادی محدود کند (Karpagachelvi, Arthanari, & Sivakumar, 2010). به همین منظور در این تحقیق از تبدیلات موجک در جهت استخراج ویژگی ها از سیگنال های ECG استفاده شده است. با استفاده از تبدیل موجک گسسته دابچیز و در چهار سطح عمل تجزیه سیگنال انجام می شود و اطلاعات فرکانس بالا در چهار سطح و فرکانس پایین در سطح چهارم استخراج می شوند.

4-5- طبقه بندی سیگنال های قلبی با استفاده از شبکه های عصبی مصنوعی

در این تحقیق از شبکه های عصبی پرسپترون چندلایه و پایه ای- شعاعی در جهت طبقه بندی سیگنال های قلبی استفاده می شود.

4-6- نتایج طبقه بندی شبکه عصبی پرسپترون چندلایه

در طبقه بندی سیگنال های قلبی از شبکه عصبی پرسپترون چندلایه با 5 ورودی در لایه ورودی، 10 نورون در لایه پنهان و یک نورون در لایه خروجی استفاده شده است و تابع فعال سازی نورون ها در لایه پنهان از نوع تانژانت هایپربولیک و در لایه خارجی از نوع علامت است. در جدول (1) انواع خطاها و معیارهای کارایی استاندارد حاصل از طبقه بندی به ازای داده های آموزشی، آزمایشی و کل داده ها نمایش داده شده است.

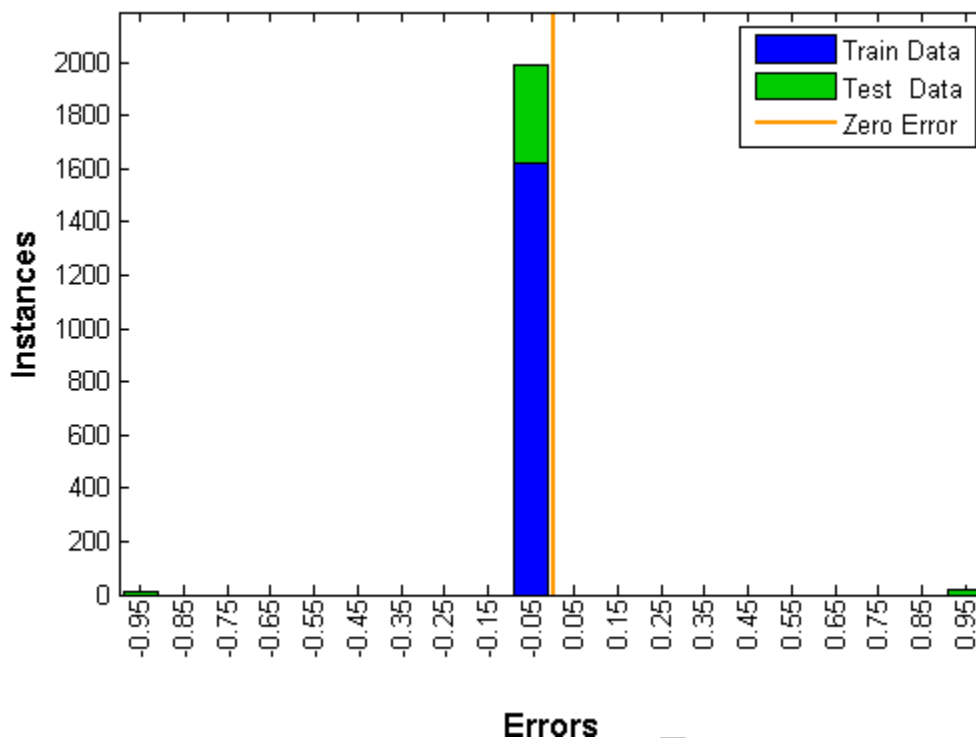
جدول 1: نتایج استفاده از شبکه عصبی پرسپترون چندلایه

	MSE	RMSE	MAE	SEE	Sn(%)	Sp(%)	PPV(%)	NPV(%)	P(%)
Train Data	0	0	0	0	100	100	100	100	100
Test Data	0.086	0.294	0.086	35	93.2	85.6	95.3	79.8	91.4
All Data	0.017	0.131	0.017	35	98.6	97.3	99.1	96	98.3

در شکل (1) هیستوگرام خطا به ازای داده های آموزشی و آزمایشی در شبکه عصبی پرسپترون چندلایه را نشان داده است. محور افقی مقدار خطا و محور عمودی فراوانی داده ها را نشان می دهد. هیستوگرام آبی رنگ میزان خطا به ازای داده های آموزشی و هیستوگرام سبز رنگ میزان خطا به ازای داده های آزمایشی را نشان می دهد.




Error Histogram with 20 Bins



شکل 1: هیستوگرام خطا به ازای داده‌های آموزشی و آزمایشی توسط شبکه عصبی پرسپترون چندلایه

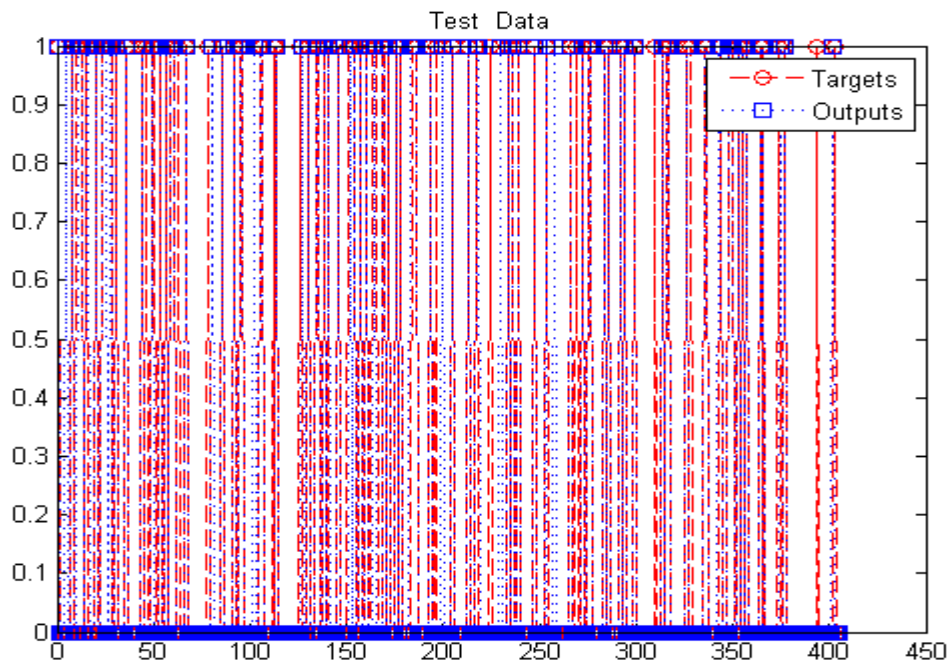
شکل (2) مقدار خروجی‌های هدف و خروجی‌های طبقه‌بند شبکه عصبی پرسپترون چندلایه به ازای داده‌های آموزشی نشان داده شده است. خروجی‌های هدف آموزشی با رنگ قرمز و خروجی‌های آموزشی طبقه‌بند با رنگ آبی نمایش داده شده است.



شکل 2: مقادیر آموزشی هدف و تخمین‌زده شده توسط شبکه عصبی پرسپترون چندلایه

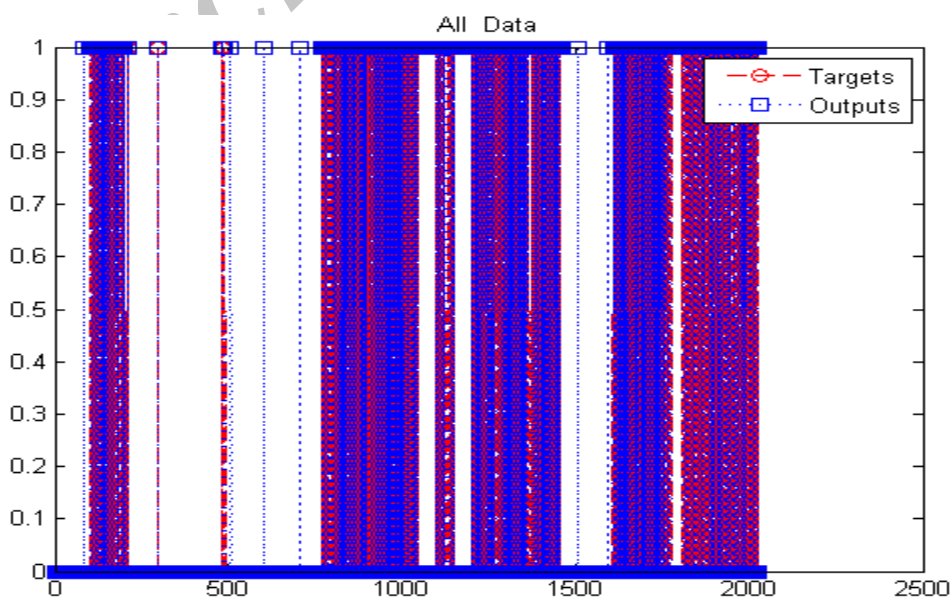


شکل (3) مقدار خروجی های هدف و خروجی های شبکه عصبی پرسپترون چندلایه به ازای داده های آزمایشی نشان داده شده است. خروجی های هدف آزمایشی با رنگ قرمز و خروجی های شبکه عصبی طبقه بند با رنگ آبی نمایش داده شده است.



شکل 3: مقادیر آزمایشی هدف و تخمین زده شده توسط شبکه عصبی پرسپترون چندلایه


شکل (4) مقدار خروجی های هدف و خروجی های شبکه عصبی طبقه بند به ازای کل داده ها نشان داده شده است. خروجی های هدف با رنگ قرمز و خروجی های شبکه عصبی طبقه بند با رنگ آبی نمایش داده شده است.



شکل 4: مقادیر هدف و تخمین زده شده توسط شبکه عصبی پرسپترون چندلایه



شکل (5) نمودار رگرسیون به ازای داده های آموزشی، آزمایشی و کل داده ها در شبکه عصبی پرسپترون چندلایه تعیین شده است. ضریب رگرسیون به ازای داده های آموزشی برابر 1، به ازای داده های آزمایشی برابر 0.769 و به ازای کل داده ها برابر 0.954 است.



شکل 5: نمودار رگرسیون به ازای داده های آموزشی، آزمایشی و کل داده ها توسط شبکه عصبی پرسپترون چندلایه

7-4- طبقه بندی با شبکه عصبی پایه ای - شعاعی

در طبقه بندی سیگنال های قلبی از شبکه عصبی پایه ای - شعاعی با 5 ورودی در لایه ورودی، 10 نورون در لایه پنهان و یک نورون در لایه خروجی استفاده شده است و تابع فعال سازی نورون ها در لایه پنهان از نوع گاوسی و در لایه خارجی از نوع خطی است. در جدول (2) انواع خطاها و معیارهای کرائی استاندارد حاصل از طبقه بندی به ازای داده های آموزشی، آزمایشی و کل داده ها نمایش داده شده است.



جدول 2: نتایج استفاده از شبکه عصبی پایه‌ای - شعاعی

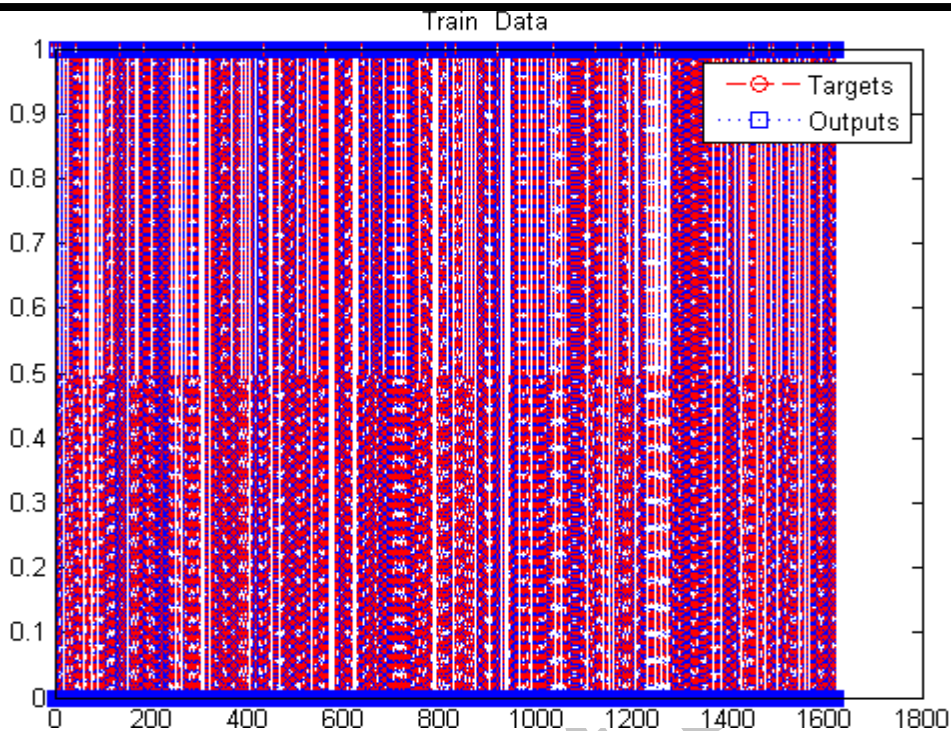
	MSE	RMSE	MAE	SEE	Sn(%)	Sp(%)	PPV(%)	NPV(%)	P(%)
Train Data	0	0	0	0	100	100	100	100	100
Test Data	0.104	0.322	0.104	42	91.3	82.9	95.5	70.8	89.6
All Data	0.021	0.144	0.021	20	98.2	97.2	99.1	94.6	97.9

در شکل (6) هیستوگرام خطا به ازای داده‌های آموزشی و آزمایشی در شبکه عصبی پایه‌ای - شعاعی را نشان داده است. محور افقی مقدار خطا و محور عمودی فراوانی داده‌ها را نشان می‌دهد. هیستوگرام آبی رنگ میزان خطا به ازای داده‌های آموزشی و هیستوگرام سبز رنگ میزان خطا به ازای داده‌های آزمایشی را نشان می‌دهد.




شکل 6: هیستوگرام خطا به ازای داده‌های آموزشی و آزمایشی توسط شبکه عصبی پایه‌ای - شعاعی

شکل (7) مقدار خروجی‌های هدف و خروجی‌های شبکه عصبی پایه‌ای - شعاعی به ازای داده‌های آموزشی نشان داده شده است. خروجی‌های هدف آموزشی با رنگ قرمز و خروجی‌های آموزشی طبقه‌بند با رنگ آبی نمایش داده شده است.



شکل 7: مقادیر آموزشی هدف و تخمین زده شده توسط شبکه عصبی پایه‌ای - شعاعی


شکل (8) مقدار خروجی‌های هدف و خروجی‌های شبکه عصبی پایه‌ای - شعاعی به ازای داده‌های آزمایشی نشان داده شده است. خروجی‌های هدف آزمایشی با رنگ قرمز و خروجی‌های آزمایشی طبقه‌بند با رنگ آبی نمایش داده شده است.



شکل 8: مقادیر آزمایشی هدف و تخمین زده شده توسط شبکه عصبی پایه‌ای - شعاعی

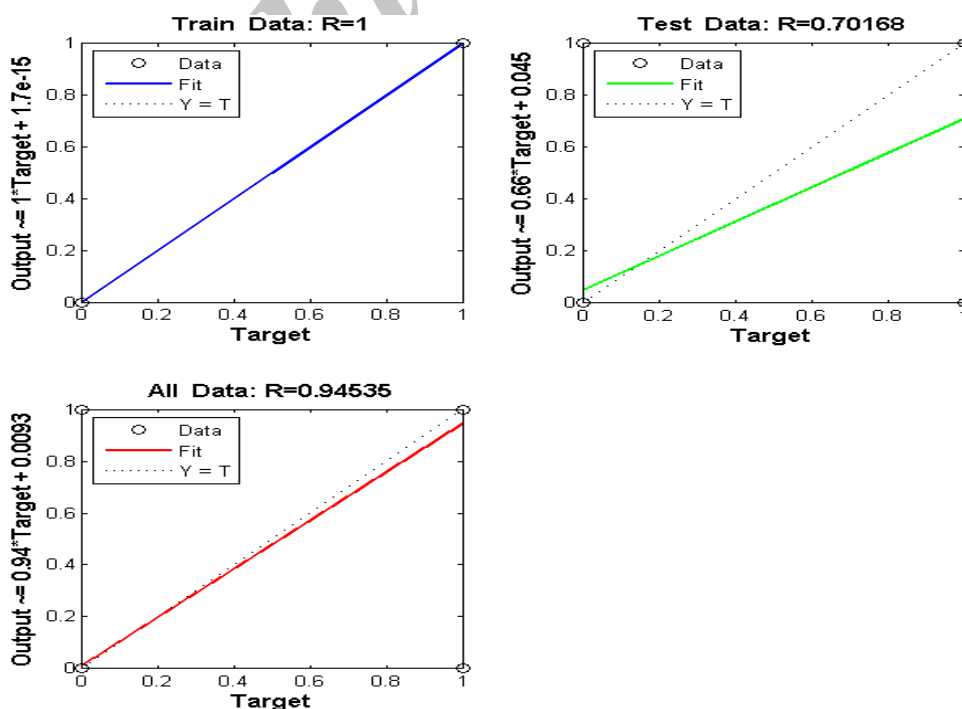


شکل (9) مقدار خروجی های هدف و خروجی های شبکه عصبی پایه ای - شعاعی به ازای کل داده ها نشان داده شده است. خروجی های هدف با رنگ قرمز و خروجی های طبقه بند با رنگ آبی نمایش داده شده است.



شکل 9: مقادیر هدف و تخمین زده شده توسط شبکه عصبی پایه ای - شعاعی

شکل (10) نمودار رگرسیون به ازای داده های آموزشی، آزمایشی و کل داده ها در شبکه عصبی پایه ای - شعاعی تعیین شده است. ضریب رگرسیون به ازای داده های آموزشی برابر 1، به ازای داده های آزمایشی برابر 0.702 و به ازای کل داده ها برابر 0.945 است.



شکل 10: نمودار رگرسیون به ازای داده های آموزشی، آزمایشی و کل داده ها توسط شبکه عصبی پایه ای - شعاعی



5- نتیجه گیری

در این تحقیق سیگنال‌های قلبی از سایت فیزیونت برداشت شده است و با روش‌های ساویتری گولای و چندجمله‌ای نویزهای فرکانس بالا و پایین حذف شد و با استفاده از تبدیلات موجک دابچیز با چهار سطح اطلاعات فرکانس پایین در سطح چهارم و اطلاعات فرکانس بالا در چهار سطح برداشت شد و در مرحله پس-پردازش از شبکه‌های عصبی پرسپترون چندلایه و پایه‌ای-شعاعی در جهت طبقه‌بندی سیگنال‌ها استفاده شد. با توجه به جداول (1) و (2) شبکه عصبی پرسپترون چندلایه با میانگین مربعات خطای 0، 0.086 و 0.017 و دقت 100%، 91.4% و 98.3% به ترتیب به ازای داده‌های آموزشی، آزمایشی و کل داده‌ها عملکرد بهتری در مقایسه با شبکه عصبی پایه‌ای-شعاعی با میانگین مربعات خطا 0، 0.104 و 0.021 و دقت 100%، 89.6% و 97.9% به ازای داده‌های آموزشی، آزمایشی و کل داده‌ها دارد.

مراجع

- [1]. Acharya, U. R., Fujita, H., Lih, O. S., Hagiwara, Y., Tan, J. H., & Adam, M. (2017). *Automated Detection of Arrhythmias Using Different Intervals of Tachycardia ECG Segments with Convolutional Neural Network*. Information sciences.
- [2]. Al Rahhal, M., Bazi, Y., AlHichri, H., Alajlan, N., Melgani, F., & Yager, R. (2016). *Deep learning approach for active classification of electrocardiogram signals*. Information sciences, 345, 340-354.
- [3]. Alickovic, E., & Subasi, A. (2015). *Effect of multiscale PCA de-noising in ECG beat classification for diagnosis of cardiovascular diseases*. Circuits, Systems, and Signal Processing, 34(2), 513-533.
- [4]. Barni, M., Failla, P., Lazzeretti, R., Sadeghi, A.-R., & Schneider, T. (2011). *Privacy-preserving ECG classification with branching programs and neural networks*. IEEE Transactions on Information Forensics and Security, 6(2), 452-468.
- [5]. Das, M. K., & Ari, S. (2014). *ECG beats classification using mixture of features*. International Scholarly Research Notices, 2014.
- [6]. Karpagachelvi, S., Arthanari, M., & Sivakumar, M. (2010). *ECG feature extraction techniques-a survey approach*. arXiv preprint arXiv:1005.0957.
- [7]. Kiranyaz, S., Ince, T., & Gabbouj, M. (2016). *Real-time patient-specific ECG classification by 1-D convolutional neural networks*. IEEE Transactions on Biomedical Engineering, 63(3), 664-675.
- [8]. Korürek, M., & Doğan, B. (2010). *ECG beat classification using particle swarm optimization and radial basis function neural network*. Expert systems with Applications, 37(12), 7563-7569.
- [9]. Kruse, R., Borgelt, C., Klawonn, F., Moewes, C., Steinbrecher, M., & Held, P. (2013). *Multi-layer perceptrons Computational Intelligence* (pp. 47-81): Springer.
- [10]. Liu, J. (2013). *Radial Basis Function (RBF) neural network control for mechanical systems: design, analysis and Matlab simulation*: Springer Science & Business Media.
- [11]. Luo, B., & Xia, J. (2014). *A novel intrusion detection system based on feature generation with visualization strategy*. Expert Systems with Applications, 41(9), 4139-4147.
- [12]. Saminu, S., Özkurt, N., & Karaye, I. A. (2014). *Wavelet feature extraction for ECG beat classification*. Paper presented at the Adaptive Science & Technology (ICAST), 2014 IEEE 6th International Conference on.
- [13]. Savitzky, A., & Golay, M. J. (1964). *Smoothing and differentiation of data by simplified least squares procedures*. Analytical chemistry, 36(8), 1627-1639.
- [14]. Thomas, M., Das, M. K., & Ari, S. (2015). *Automatic ECG arrhythmia classification using dual tree complex wavelet based features*. AEU-International Journal of Electronics and Communications, 69(4), 715-721.



- [15]. Vafaie, M., Ataei, M., & Koofigar, H. R. (2014). *Heart diseases prediction based on ECG signals' classification using a genetic-fuzzy system and dynamical model of ECG signals*. Biomedical Signal Processing and Control, 14, 291-296.
- [16]. Yang, J., Bai, Y., Lin, F., Liu, M., Hou, Z., & Liu, X. *A novel electrocardiogram arrhythmia classification method based on stacked sparse auto-encoders and softmax regression*. International Journal of Machine Learning and Cybernetics, 1-8.
- [17]. Zhang, C., Wang, G., Zhao, J., Gao, P., Lin, J., & Yang, H. (2017). *Patient-specific ECG classification based on recurrent neural networks and clustering technique*. Paper presented at the Biomedical Engineering (BioMed), 2017 13th IASTED International Conference on.

Archive of SID